

**T.C.
MANİSA CELAL BAYAR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ**

**DOKTORA TEZİ
İŞLETME ANABİLİM DALI
İŞLETME DOKTORA PROGRAMI**

**ŞEHİR İÇİ TOPLU TAŞIMA PLANLAMASINDA AKILLI KART
VERİ MADENCİLİĞİ İLE SEFER SIKLIĞI OPTİMİZASYONU**

B. Türker PALAMUTÇUOĞLU

**Danışman
Doç. Dr. Mustafa GERŞİL**

MANİSA - 2020

**T.C.
MANİSA CELAL BAYAR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ**

**DOKTORA TEZİ
İŞLETME ANABİLİM DALI
İŞLETME DOKTORA PROGRAMI**

**ŞEHİR İÇİ TOPLU TAŞIMA PLANLAMASINDA AKILLI KART
VERİ MADENCİLİĞİ İLE SEFER SIKLIĞI OPTİMİZASYONU**

Bedrettin Türker PALAMUTÇUOĞLU

**Danışman
Doç. Dr. Mustafa GERŞİL**

MANİSA – 2020

	T.C. MANİSA CELAL BAYAR ÜNİVERSİTESİ SOSYAL BİLİMLER ENSTİTÜSÜ	Doküman Kodu	FRDR-031
	DOKTORA EĞİTİMİ FORMLARI Tez Savunma Sınavı Tutanağı	Yayınlanma Tarihi	26/03/2018
		Revizyon No/Tarih	2-/28/02/2018
		Sayfa	1/1

TEZ SAVUNMA SINAV TUTANAĞI

Manisa Celal Bayar Üniversitesi Sosyal Bilimler Enstitüsü 07/01/2020 tarih ve 1/7 sayılı toplantısında oluşturulan jürimiz tarafından Manisa Celal Bayar Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği'nin 22. maddesi gereğince İşletme Anabilim Dalı İşletme Doktora Programı öğrencisi Bedrettin Türker PALAMUTÇUOĞLU'nun **"Şehiriçi Toplu Taşıma Planlamasında Akıllı Kart Veri Madenciliği ile Sefer Sıklığı Optimizasyonu"** konulu tezi incelenmiş ve aday 12.02.2020 tarihinde saat 10:00'da jüri önünde tez savunmasına alınmıştır.

Adayın kişisel çalışmaya dayanan tezini savunmasından sonra 90 dakikalık süre içinde gerek tez konusu, gerekse tezin dayanağı olan anabilim dallarından jüri üyelerine sorulan sorulara verdiği cevaplar değerlendirilerek tezin,

BAŞARILI olduğuna ☒ OY BİRLİĞİ ☒
DÜZELTME yapılmasına * ☐ OY ÇOKLUĞU ☐
RED edilmesine ** ☐ ile karar verilmiştir.

BAŞKAN

Doç. Dr. Mustafa Kemal Pala

ÜYE Prof. Dr. Cağrı Z. Yılmaz

ÜYE

Dr. Öğretim Üyesi Özgür Elçi

ÜYE Dr. Öğr. Üyesi Uğur ELİA

ÜYE DR. Öğr. Üyesi BERAN GÜLBAĞEK TOLUN

Evet Hayır

Tez, burs, ödül veya Teşvik programına (Tüba, Fullbright vb.) aday olabilir.

☐ ☒

Tez, mutlaka basılmalıdır.

☐ ☒

Tez, mevcut haliyle basılmalıdır.

☐ ☒

Tez, gözden geçirildikten sonra basılmalıdır.

☒ ☐

Tez, basımı gereksizdir.

☐ ☐

* Bu halde adaya 6 ay süre verilir. İkinci tez savunma sınavında da başarısız olan öğrencinin Enstitü ile ilişkisi kesilir.

** Bu halde adayın Enstitü ile ilişkisi kesilir.

Hazırlayan
Enstitü Sekreteri

Onaylayan
Enstitü Müdürü

YEMİN METNİ

Doktora tezi olarak sunduđum “Şehir içi Toplu Taşıma Planlamasında Akıllı Kart Veri Madenciliđi İle Sefer Sıklığı Optimizasyonu” adlı çalışmanın, tarafımdan bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın yazıldığını ve yararlandığım eserlerin bibliyografyada gösterilen eserlerden oluştuđunu, bunlara atıf yapılarak yararlanmıř olduđumu belirtir ve bunu onurumla doğrularım.

.../.../2020

B. Türker PALAMUTÇUOđLU

İmza

ÖZET

ŞEHİRİÇİ TOPLU TAŞIMA PLANLAMASINDA AKILLI KART VERİ MADENCİLİĞİ İLE SEFER SIKLIĞI OPTİMİZASYONU

Şehir içi toplu taşımada akıllı kart ile ücretlendirme işlemleri her geçen gün daha yaygın bir hale gelmektedir. Bu akıllı kart ile yapılan ödeme ve binişlerin kaydı büyük veritabanlarında tutulmaktadır. Akıllı kart işlemlerine ilişkin bu veriler tüketici davranış kalıplarını anlama, hat hizmet güvenilirliğini ve performansını ölçme, başlangıç – varış matrisi tahmini, gelecekteki talebin öngörülmesi, optimum sefer sıklıklarının belirlenmesi, hat güzergahlarının yeniden düzenlenmesi gibi planlama faaliyetlerinde kullanılabilme potansiyeli taşımaktadır.

Akıllı kart verilerine çeşitli veri madenciliği yöntem ve teknikleri uygulanarak tüketici davranışları anlaşılabilir, tüketici gruplarının gösterdiği davranışlara uygun bazı öneriler sunulabilir. Akıllı kart otobüs servis verileri yardımıyla otobüslerin sunulan çizelgeye ne ölçüde uygun hareket ettikleri tespit edilebilir ve güvenilirlik ölçümleri yapılabilir. Çoğu akıllı kart ücretlendirme sistemlerinde sadece biniş esnasında kart gösterilir, iniş esnasında kartın tekrar gösterilmesi söz konusu değildir. Bu nedenle veritabanlarında genellikle sadece biniş duraklarına ilişkin veriler mevcuttur. Bu durumda bir başlangıç – varış matrisi ve gelecekteki talep öngörülerini tahmin edebilmek için öncelikle biniş duraklarından iniş duraklarının tahmini gereklidir. Literatürde yaygın olarak yolculuk zincirleme algoritmasından faydalandığı görülmektedir. Bu yöntemle yolculukların önemli bir kısmı için iniş durakları tahmin edilebilmektedir. Biniş ve iniş durakları belli ise başlangıç – varış matrislerinin oluşturulması ve talep öngörüsü için gerekli veriler hazır hale gelir. Gelecek öngörüsünde çok çeşitli yöntemler kullanılabilir.

Bu çalışmanın amacı; toplu taşıma planlamasında akıllı kart verilerinin gizli potansiyelini ortaya çıkartmak ve planlamacılara bu verileri ne şekilde kullanabileceklerini göstererek yol göstermektir. Yapılan uygulamada veri madenciliği yöntemleriyle bu büyük veri yığınlarından faydalı verilerin nasıl elde edilebileceği, elde edilen yeni verilerin planlama için nasıl kullanılabileceğini göstermek amaçlanmıştır.

Bu çalışmada biniş duraklarından iniş duraklarını tahmin etmek üzere yolculuk

zincirleme algoritması, Diker'in önerdiği rastgele atama tahmin yöntemi kullanılmıştır. Kullanılan diğer algoritmalar: k-ortalamlar, x-ortalamlar kümeleme algoritmaları, biniş ve iniş duraklarından başlangıç – varış matrisi hesaplaması yapan algoritma, gelecek öngörüsü için ileri beslemeli geriye yayılım algoritması içeren çok katmanlı algılayıcı tipinde yapay sinir ağı, sefer sıklığı optimizasyonu için hedef programlama formülasyonunda önerilen basit bir algoritmik yaklaşım ve genetik algoritmadır.

Çalışmanın ilk bölümünde toplu taşıma ve planlamasında akıllı kart kullanımı, akıllı kart verilerinden çeşitli veri madenciliği yöntemleriyle bilgi keşfine, performans ölçümüne ve planlama faaliyetlerine ilişkin literatür özeti sunulmuştur. İkinci bölümde veri madenciliğinin uygulama alanları, veri madenciliği süreci, kullanılan yöntemlere ilişkin literatür özeti sunulmuştur. Üçüncü bölümde araştırmada kullanılan algoritmalarla ilişkin literatür araştırması bulguları özetlenmiştir. Bu bölümde optimum sefer sıklığının belirlenmesi için geliştirilen basit yaklaşım hakkında da bilgi verilmiştir. Dördüncü bölümde araştırmanın amacı, kapsamı, varsayımları, sınırlılıkları, yöntemler, verilerin elde edilmesi, prototip uygulamanın gelişim süreci, esas uygulama ve sonuçları sunulmuştur.

Araştırmada birçok bulgu elde edilmiştir. Öncelikle biniş duraklarından iniş duraklarını tespit eden algoritmalar çalıştırılmıştır. Yolculuk zincirleme algoritması ile iniş duraklarının ortalama % 58,68'i tahmin edilebilmiştir. Kalan iniş duraklarının % 37,63'ü rastgele atama tahmin yöntemi ile, % 3,69'u ise son durağı iniş durağı olarak atama yöntemi ile belirlenmiştir. Konak bağlantılı 10 otobüs hattı için başlangıç – varış matrisleri hesaplanmış ve verilerin kapsadığı tarihlerde her zaman dilimi için maksimum talep düzeyleri hesaplanmıştır. Bu talep verilerinden hafta sonuna ilişkin bir yapay sinir ağı (YSA), hafta içine ilişkin başka bir YSA ayrı ayrı eğitilmiştir. YSA'nın yanı sıra hareketli ortalamlar, ağırlıklı hareketli ortalamlar, üstel düzeltme ve regresyon modelleri de oluşturulmuş ve tahmin performansları test edilmiştir. En iyi tahminlerin YSA ile elde edildiği görülmüştür. Optimum sefer sıklığını belirlemek için hedef programlamaya dayanan matematiksel modeller hem basit algoritma hem de genetik algoritma ile çözülmüş ve sonuçlar karşılaştırılmıştır. Genetik algoritma ile önerdiğimiz algoritma optimum sonuçları vermiştir.

Anahtar Kelimeler: Akıllı Kart Veri Analizi, Sefer Sıklığı Optimizasyonu, Veri Madenciliği, Yapay Sinir Ağı, Genetik Algoritma, BV Matris Tahmini.

ABSTRACT

OPTIMIZATION OF HEADWAY WITH SMART CARD DATA MINING IN URBAN PUBLIC TRANSPORTATION PLANNING

In public transport, smart card charging is becoming more common. The registration of payment and boarding with smart card is kept in large databases. These data related to smart card transactions have the potential to be used in planning activities such as understanding consumer behavior patterns, measuring line service reliability and performance, estimating the origin - destination matrix, predicting future demand, determining optimum travel frequencies, and reordering line routes.

By applying various data mining methods and techniques to smart card data, consumer behaviors can be understood and some suggestions can be presented to the behavior of consumer groups. With the help of the smart card bus service data, it is possible to determine the extent to which buses behave in accordance with the schedule and reliability measurements can be made. In most smart card pricing systems, the card is shown only during boarding, and the card is not displayed again during alighting. Hence, only data on boarding stops are usually available in databases. In this case, an estimate of alighting stops from boarding stops are necessary to an origin - destination matrix and predict future demand forecasts. In the literature, it is seen that travel chain algorithm is widely used. With this method, alighting stops can be estimated for most of the trips. If the boarding and landing stops are certain, the data required for the creation of the start - arrival matrices and the demand forecast are ready. A variety of methods can be used for future forecasting.

The aim of this study is; to expose the hidden potential of smart card data in public transport planning and to show the planners how to use this data. It is aimed to show how useful data can be obtained from these large data heaps by using data mining methods and how new data can be used for planning.

In this study, travel chaining algorithm and Diker's random assignment estimation method are used to estimate descent stops from boarding stops. Other algorithms used: k-means, x-means clustering algorithms, origin-destination matrix computation algorithm, and feed forward back-propagational multilayer perceptron

type artificial neural network for future prediction, recommended simple algorithm and genetic algorithm with target programming formulation for optimum headway.

In the first part of the study, use of smart cards in public transportation and planning, the literature review of knowledge discovery, performance measurement and planning activities is presented through various data mining methods from smart card data. In the second part, literature review of the application areas of data mining, data mining process, about the methods used are presented. In the third chapter, the findings of the literature research related to the algorithms used in the study are summarized. In the third chapter, the findings of the literature research related to the algorithms used in the study are summarized. This chapter also provides information on the simple approach for determining the optimum frequency of travel. In this chapter, information on the simple approach for determining the optimum headway is presented.

Many findings were obtained in the study. First of all, the algorithms that identified the alighting stops from the boarding stops was run. An average of 58.68% of the alighting stops were estimated by the trip chaining algorithm. 37,63% of the remaining alighting stops were determined by random assignment estimation method and 3,69% by assignment to final stop as alighting method. Origin - destination matrices were calculated for 10 bus lines with a Konak connection and maximum demand levels were calculated for each time period at the time of data scope. From this demand data, a separate ANN was run with data on weekends and an ANN for the weekday. In addition to ANN, moving averages, weighted moving averages, exponential smoothing and regression models have been developed and the performance estimations have been tested. The most accurate predictions were obtained with ANN. In order to determine the optimum frequency, the mathematical models based on the target program were solved by both simple and genetic algorithms and the results were compared. The genetic algorithm and the algorithm we proposed gave optimum results.

Keywords: Smart Card Data Analysis, Headway Optimization, Data Mining, Artificial Neural Network, Genetic Algorithm, OD Matrix Estimation.

TEŞEKKÜR

Çalışmamın her aşamasında bana destek olan, bilgi ve deneyimleri ile yol gösteren danışman hocam Sayın Doç. Dr. Mustafa GERŞİL'e, bilgi ve tecrübesi ile lisansüstü öğrenim hayatımın tüm zorlu aşamalarında her yönden yardımcı olan, tecrübeleri ile beni aydınlatan ve desteğini hiç eksik etmeyen, kendisini tanımaktan büyük onur duyduğum sevgili hocam Sayın Prof. Dr. Cengiz YILMAZ'a, Tez çalışmamın her aşamasında bilgi ve deneyimleri ile yol gösteren hocalarım Sayın Dr. Öğr. Üyesi Özgür ESKİ'ye ve Dr. Öğretim Üyesi Uğur ELİİYİ'ye, çalışmalarım için gerekli verileri sağlayan, önerilerde bulunan ESHOT Genel Müdürlüğü, Ulaşım Planlama Dairesi Başkanlığı, İstatistik Şube Müdürlüğü çalışanlarına, öğrenim hayatım boyunca beni maddi ve manevi olarak destekleyen ve hep yanımda olan başta eşim Aynur PALAMUTÇUOĞLU olmak üzere bütün aileme yürekten teşekkür ederim.

B. Türker PALAMUTÇUOĞLU
Manisa, 2020

İÇİNDEKİLER

ÖZET.....	v
ABSTRACT.....	vii
SİMGELER ve KISALTMALAR DİZİNİ	xvi
TABLOLAR LİSTESİ.....	xix
ŞEKİLLER LİSTESİ	xxii
EKLER.....	xxv
GİRİŞ	1

BİRİNCİ BÖLÜM

TOPLU TAŞIMA PLANLAMASI VE AKILLI KART VERİLERİ KULLANIMI	
1.1. TOPLU TAŞIMA PLANLAMASI.....	5
1.1.1. Ulaşım Ana Planı	6
1.1.1.1. Ulaşım Ana Planı Yapım Aşamaları	7
1.1.2. Acil Eylem Ulaşım ve Trafik İyileştirme Plan, Etüt ve Projeleri	18
1.1.3. Raylı Sistem Hatları Ön/Kesin Projeleri ve Fizibilite Etütleri	19
1.2. TOPLU TAŞIMA PLANLAMASINDA AKILLI KART VERİLERİNİN KULLANIMI.....	20
1.2.1. Akıllı Kart Verileri ile Toplu Taşıma Performansının Ölçümü.....	21
1.2.2. Akıllı Kart Verilerinden Başlangıç-Variş (Origin-Destination - OD Matris) Matrislerinin Tahmini.....	22
1.2.3. Akıllı Kart Verilerine Veri Madenciliği Süreçlerinin Uygulanması	22
1.2.4. Akıllı Kart Verileriyle Toplu Taşıma Rota Planlaması	24
1.2.5. Akıllı Kart Verileriyle Optimum Sefer Sıklığı Planlaması.....	24
1.2.6. Akıllı Kart Verilerinden Yolcu Davranışlarının Analizi	25
1.2.7. Akıllı Kart Verilerinden İniş Duraklarının Tahmini.....	26
1.2.8. Jeodezik Mesafe Ölçüleri.....	29
1.2.8.1. Kısa Mesafe Ölçüleri.....	29
1.2.8.2. Uzun Mesafede Kullanılan Ölçüler	31
1.3. BAŞLANGIÇ-VARIŞ MATRİSLERİNİN TAHMİNLENMESİ	35
1.3.1. Geleneksel Veri Toplama Yöntemleri	35
1.3.1.1. Anketler	35
1.3.1.2. Trafik Sayımları	36
1.3.2. Yeni Veri Toplama Yöntemleri	39
1.3.2.1. Coğrafi Konumlama Sistemi (GPS) Verileri.....	39
1.3.2.2. Akıllı Kart Verileri	39

1.4. BAŞLANGIÇ-VARIŞ MATRİSLERİNDEN HAT TALEBİNİN HESAPLANMASI.....	40
1.5. SEFER SIKLIĞI OPTİMİZASYONU (SEFER ÇİZELGELEME)	41

İKİNCİ BÖLÜM

VERİ MADENCİLİĞİ

2.1. VERİ MADENCİLİĞİ KAVRAMI.....	44
2.2. VERİ MADENCİLİĞİNİN UYGULAMA ALANLARI.....	44
2.2.1. Sağlık Alanında Uygulamalar.....	44
2.2.2. Endüstri ve Mühendislik Alanında Uygulamalar	45
2.2.3. Kamu Alanında Uygulamalar	47
2.2.4. Ticaret ve Pazarlama Alanında Uygulamalar	48
2.2.5. Bankacılık, Finans ve Borsa Alanında Uygulamalar.....	52
2.2.6. İnternet Alanında Uygulamalar	53
2.2.7. Eğitim Alanında Uygulamalar	53
2.3. KULLANILAN YÖNTEMLER	55
2.3.1. Karakterizasyon ve Ayırma	55
2.3.2. Sık Desen, Birliktelik ve Korelasyon Madenciliği	56
2.3.3. Tahminleyici Analizler (Sınıflandırma, Regresyon ve Zaman Serisi Analizleri)	57
2.3.4. Sınıflandırma	57
2.3.5. Regresyon Analizi.....	58
2.3.6. Zaman Serisi Analizi	58
2.3.7. Kümeleme Analizi	59
2.3.8. Sıradışılık (istisna – uç değer) Analizi (Outlier Analysis).....	61
2.4. VERİ MADENCİLİĞİ SÜRECİ	61
2.4.1. Veri Ön-İşleme	62
2.4.2. Veri Toplama (Data Aggregation).....	62
2.4.2.1. Veri Temizleme (Data Cleaning)	63
2.4.2.2. Veri Dönüştürme (Data Transformation)	63
2.4.2.3. Veri İndirgeme (Data Reduction).....	65
2.4.2.4. Veri Azaltma	65
2.4.2.5. Veri Küpleri (Data Cube)	65
2.4.2.6. Boyut İndirgeme	66
2.4.2.7. Kesikli Hale Getirme	66
2.4.2.8. Örneklem	67
2.4.3. Modelleme (Algoritmanın Uygulanması).....	67

2.4.4.	Sonuçların İncelenmesi.....	67
--------	-----------------------------	----

ÜÇÜNCÜ BÖLÜM

ARAŞTIRMADA KULLANILAN ALGORİTMALAR

3.1.	AKILLI KART VERİLERİNDEN DURAK BAZINDA BAŞLANGIÇ-VARIŞ MATRİSİNİN HESAPLANMASINA İLİŞKİN ALGORİTMALAR	68
3.2.	YAPAY SİNİR AĞLARI	74
3.2.1.	Yapay Sinir Ağlarının Genel Özellikleri	75
3.2.2.	Yapay Sinir Ağlarının Gelişimi	77
3.2.3.	Yapay Sinir Ağı Türleri	81
3.2.4.	Yapay Sinir Ağlarının Kullanım Alanları.....	82
3.3.	HEDEF PROGRAMLAMA	84
3.3.1.	Hedef Programlamanın Uygulama Alanları	84
3.3.2.	Karar Değişkenlerinin Belirlenmesi	85
3.3.3.	Sistem Kısıtlarının Belirlenmesi	85
3.3.4.	Hedef Kısıtlarının Belirlenmesi	85
3.3.5.	Amaç Denklemin Tanımlanması	86
3.4.	GENETİK ALGORİTMALAR	87
3.4.1.	Genetik Algoritma Kavramı ve Gelişimi.....	87
3.4.2.	Genetik Algoritma Türleri	92
3.4.3.	Genetik Algoritmanın Çalışma Süreci.....	92
3.4.4.	Kodlama.....	93
3.4.5.	Uygunluk Fonksiyonu.....	93
3.4.6.	Başlangıç Popülasyonu	94
3.4.7.	Seçim ve Üreme Operatörleri	95
3.4.7.1.	Rulet Tekerleği Seçimi (Roulette Wheel Selection)	95
3.4.7.2.	Sıralama Seçimi (Rank Selection).....	95
3.4.7.3.	Uniform Seçim (Uniform Selection).....	95
3.4.7.4.	Turnuva Seçimi (Tournament Selection)	96
3.4.7.5.	Kararlı Durum Seçimi (Steady State Selection).....	96
3.4.8.	Çaprazlama ve Mutasyon Operatörleri	96
3.4.8.1.	Çaprazlama	96
3.4.8.2.	Mutasyon Operatörü (Mutation)	97
3.4.9.	Erken Yakınsama Problemi ve Ölçekleme	98
3.4.10.	Seçkinlik (Elitizm) Kavramı	99
3.4.11.	Parametre Optimizasyonu	99
3.4.12.	Melez Yaklaşımlar	101

3.5.	GELİŞTİRİLEN ALGORİTMİK YAKLAŞIM	102
3.5.1.	Hedef Programlama Modeli ve Amaç Denklem.....	102
3.5.2.	Önerilen Yöntem.....	106
3.5.3.	Yöntem İçin Uygulama Örneği.....	108

DÖRDÜNCÜ BÖLÜM

ESHOT GENEL MÜDÜRLÜĞÜ UYGULAMASI

4.1.	ARAŞTIRMANIN AMACI.....	111
4.2.	ARAŞTIRMANIN KAPSAMI	112
4.3.	ARAŞTIRMANIN VARSAYIMLARI	112
4.4.	ARAŞTIRMANIN SINIRLILIKLARI.....	112
4.5.	ARAŞTIRMANIN YÖNTEMLERİ	113
4.6.	VERİLERİN ELDE EDİLMESİ.....	114
4.7.	ARAŞTIRMANIN LİTERATÜRE KATKISI	113
4.8.	PROTOTİP UYGULAMA	116
4.8.1.	Akıllı Kart Veri Yapısı	116
4.8.2.	Trépanier, Chapleau ve Tranchant (2007) ve Diker (2015) Yaklaşımları Kullanılarak İniş Duraklarının Tespiti	117
4.8.2.1.	Verilerin Yolculuk Zincirleme İçin Hazırlanması.....	117
4.8.2.2.	Yolculuk Zincirleme Yaklaşımı	118
4.8.2.3.	Diker'in Rastgele Atama Tahmin Yöntemi ve Son Durağı Atama Yöntemi	119
4.8.2.4.	Biniş Duraklarından İniş Duraklarını Tahminleyen Algoritmanın Sözde Kodu	119
4.8.2.5.	Kullanıcı Biniş ve İniş Durakları ile Başlangıç-Varış (BV) Matrislerinin Oluşturulması ve Maksimum Talep Düzeyinin Hesaplanması ..	121
4.9.	PROTOTİP UYGULAMA İÇİN VERİ ANALİZİ	121
4.9.1.	Verilerin Veri Madenciliği Yöntemleri ile İncelenmesi (Kart Kullanım Kalıplarının Belirlenmesi).....	125
4.9.1.1.	Verilerin Kümeleme Analizine Hazırlanması	125
4.9.1.2.	Eksik Verilerin Değiştirilmesi (Imputation).....	126
4.9.1.3.	Veri Ön İşleme Süreci	126
4.9.1.4.	Kümeleme Analizinin Gerçekleştirilmesi	127
4.9.2.	Hatlara İlişkin Maksimum Talep Düzeylerini Tahminleyen Yapay Sinir Ağı Yaklaşımı	130
4.9.2.1.	Geliştirilen Çok Katmanlı Algılayıcı Tipindeki İleri Beslemeli Yapay Sinir Ağı Modeli	131
4.9.2.2.	Geliştirilen YSA'nın Performansının Belirlenmesi.....	131

4.9.2.3.	Geliştirilen Yapay Sinir Ağı'nın Parametre Optimizasyonu	132
4.9.2.4.	Aktivasyon Fonksiyonlarının Belirlenmesi.....	132
4.9.2.5.	Gizli Katman Sinir Hücresi Sayısının Belirlenmesi.....	133
4.9.2.6.	Öğrenme Oranı ve Momentumun Belirlenmesi	134
4.9.2.7.	Başlangıç Ağırlık Katsayılarının Değer Aralığının Belirlenmesi ..	135
4.9.3.	Geliştirilen Yapay Sinir Ağı'nın Testi ve Diğer Tahmin Yaklaşımlarıyla Karşılaştırılması	136
4.9.3.1.	Eğitimi Tamamlanan Yapay Sinir Ağı ile Yapılan Tahminler ve Hesaplanan İstatistikler	136
4.9.3.2.	Yapay Sinir Ağı ile Hareketli Ortalamalar Yönteminin Performanslarının Karşılaştırılması	138
4.9.3.3.	Yapay Sinir Ağı ile Ağırlıklı Hareketli Ortalamalar Yönteminin Performanslarının Karşılaştırılması	138
4.9.3.4.	Yapay Sinir Ağı ile Üstel Düzeltme Yönteminin Performanslarının Karşılaştırılması	139
4.9.3.5.	Yapay Sinir Ağı ile Çoklu Doğrusal Regresyon Yönteminin Performanslarının Karşılaştırılması	140
4.9.3.6.	Tahminleme Yöntemlerinin Bir Arada Değerlendirilmesi.....	141
4.10.	HATLAR İÇİN KAPASİTE ve TALEP DÜZEYLERİNİ DİKKATE ALARAK OPTİMUM SEFER SIKLIĞININ BELİRLENMESİNDE KULLANILAN YAKLAŞIM.....	142
4.10.1.	Hatlar İçin Kapasite ve Zaman Kısıtları Dikkate Alınarak Optimum Sefer Sıklığının Belirlenmesi İçin Geliştirilen Modeller	142
4.10.2.	Hatlar İçin Kapasite ve Zaman Kısıtları ile Durakta Bekleme Süreleri Dikkate Alınarak Optimum Sefer Sıklığının Belirlenmesi İçin Geliştirilen Modeller	143
4.10.3.	Hatlar İçin Kapasite, Zaman Kısıtları ve Durakta Bekleme Süreleri ile Araç İçinde m^2 'ye Düşen Yolcu Sayısı Dikkate Alınarak Optimum Sefer Sıklığının Belirlenmesi İçin Geliştirilen Modeller.....	144
4.10.4.	Hatlar İçin Kapasite, Zaman Kısıtları, Durakta Bekleme Süreleri, Araç İçinde m^2 'ye Düşen Yolcu Sayısı ve Sefer Maliyeti Dikkate Alınarak Optimum Sefer Sıklığının Belirlenmesi için Geliştirilen Modeller	145
4.10.5.	Model 13'de MDYS için Sistem Kısıtı Konulan Model.....	146
4.10.6.	Optimum Sefer Sıklığı Optimizasyon Modellerinin 802 Nolu Egekent Aktarma - Konak Hattı için Karşılaştırılması	147
4.10.7.	Duyarlılık Analizi.....	149
4.10.7.1.	Pozitif Sapmalar Ağırlık Katsayısı İçin Duyarlılık Analizi	149
4.10.7.2.	Negatif Sapmalar Ağırlık Katsayısı için Duyarlılık Analizi	150
4.10.7.3.	Durakta Bekleme Süresi Ağırlık Katsayısı için Duyarlılık Analizi	150
4.10.7.4.	Maliyet Ağırlık Katsayısı için Duyarlılık Analizi	152

4.10.7.5.	m^2 'ye Düşen Yolcu Sayısı Ağırlık Katsayısı için Duyarlılık Analizi	153
4.11.	OPTİMUM SEFER SIKLIKLARININ TESPİTİ İÇİN GELİŞTİRİLEN GENETİK ALGORİTMA	154
4.11.1.	Kodlama ve Genetik Yapı.....	154
4.11.2.	Uygunluk Fonksiyonu.....	155
4.11.3.	Başlangıç Popülasyonunun Oluşturulması.....	155
4.11.4.	Seçim ve Üreme Operatörü.....	155
4.11.5.	Çaprazlama Operatörü	156
4.11.6.	Mutasyon Operatörü.....	156
4.12.	ALGORİTMANIN UYGULANMASI	157
4.12.1.	Biniş Duraklarından İniş Duraklarının Tahmini Algoritmasının Performansı	157
4.12.2.	Durak Seviyesinde BV Matris Tahmini	178
4.12.3.	Hesaplanan Talep Verilerine Göre Talep Tahmini	179
4.12.4.	Tahmini Talep ve Hat Parametreleri Kullanılarak Optimum Sefer Sıklıklarının Önerilen Algoritma ile Belirlenmesi.....	180
4.12.5.	Tahmini Talep ve Hat Parametreleri Kullanılarak Optimum Sefer Sıklıklarının Genetik Algoritma ile Belirlenmesi	226
4.12.6.	Modellerin Toplu Değerlendirilmesi.....	233
5.	SONUÇ	236
6.	KAYNAKÇA	241
	EKLER.....	278

SİMGELER ve KISALTMALAR DİZİNİ

1X	1 Point Crossover
2X	İki Point Crossover
ADALINE	Adaptive Linear Unit
AIS	Agrawal, Imelinski, Swami
ALSM	Assignment to Last Stop Method
APC	Automatic Passenger Counter
APTS	Advanced Public Transportation System
ARAAP	Açgöz Rastgele Adaptif Arama Prosedürü
ARIMA	AutoRegressive Integrated Moving Average
ART	Adaptive Resonance Theory
AVL	Automatic Vehicle Location
AX	Aritmetic Crossover
BÖTE	Bilgisayar ve Öğretim Teknolojileri Eğitimi
BRT	Bus Rapid Transit
BV	Başlangıç – Varış
CART	Classification And Regression Trees
CE	Classification Error
CHAID	Chi-Squared Automatic Interaction Detector
CHARM	Closed Association Rule Mining
CLIQUE	Clustering In Quest
CRM	Customer Relationship Management
CRT	Classification and Regression Trees
CX	Cycle Crossover
DBSCAN	Density Based Spatial Clustering of Applications with Noise
DENCLUE	Density –Based Clustering
DFT	Discrete Fourier Transform
DHP	Doğrusal Hedef Programlama
DMAIC	Define – Measure – Analyze – Improvement – Control
DWT	Discrete Wavelet Transform
ESB	Elliot Simetrik Birim
ESHOT	İzmir Elektrik, Su, Havagazı, Otobüs ve Trolleybüs
GA	Genetik Algoritma

GPS	Global Positioning System
HP	Hedef Programlama
HSA	Hanehalkı Seyahat Anketi
IC	Identity Card
ID3	Iterative Dichotomiser 3
İETT	İstanbul Elektrik Tramvay ve Tünel İşletmeleri
İZSU	İzmir Su ve Kanalizasyon İdaresi
KBDA	Otobüste Kişi Başına Düşen Alan
KKO	Karınca Kolonisi Optimizasyonu
KNN	K Nearest Neighbourhood
LOX	Linear Order Crossover
LVQ	Learning Vector Quantization
LX	Logic Crossover
MADALINE	Multiple Adaptive Linear Unit
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MO	Mutasyon Oranı
MPE	Mean Percentage Error
MSE	Mean Square Error
NX	N Point Crossover
OBX	Order Based Crossover
OD	Origin – Destination
OLAP	OnLine Analytical Processing
OPTICS	Ordering Points To Identify the Clustering Structure
ÖSYM	Öğrenci Seçme ve Yerleştirme Merkezi
OX	Ordered Crossover
PBX	Poisition Based Crossover
PCA	Principal Component Analysis
PCU	Passenger Car Unit
PMX	Partially Mapped Crossover
PNN	Probabilistic Neural Network
RAEM	Random Assignment Estimation Method
RARM	Rapid Association Rule Mining
RBN	Radial-Basis Network

RFID	R adio F requency I dentification
RMSE	R oot M ean S quare E rror
SETM	S et- O riented M ining
SLIQ	S upervised L earning I n Q uest
SOM	S elf O rganizing M ap
SPRINT	S calable P arallelizable I nduction O f D ecision T rees
SQL	S tructured Q uery L anguage
SSE	S um of S quared E rror
STING	S tatistical I nformation G rid-based method
SVC	S upport V ector C lustering
SVD	S ingular V alue D ecomposition
TEFE	T optan E şya F iyat E ndeksi
TEK	T ürk E lektrik K urumu
TÜFE	T üketici F iyat E ndeksi
TÜİK	T ürkiye İ statistik K urumu
ÜDB	Ü stel D oğrusal B irim
UX	U niform C rossover
VTBK	V eri T abanlarında B ilgi K eşfi
YSA	Y apay S inir A ğı

TABLÖLER LİSTESİ

Tablo 1: Başlangıç-Varış Matrisi Örneği.....	41
Tablo 2: Akıllı Kart Verilerinden Başlangıç-Varış Matrislerinin Hesaplanmasına İlişkin Literatür Araştırması.....	68
Tablo 3: Yapay Sinir Ağı Alanında Yapılan Akademik Çalışmalar.....	78
Tablo 4 : Genetik Algoritmanın Tarihsel Gelişim Süreci.....	88
Tablo 5: Sefer Sıklığı Optimizasyon Algoritmasının Adım Adım İşleyişi.....	108
Tablo 6: Ağırlık Katsayıları Uygulandığında Algoritmanın İşleyişi.....	109
Tablo 7: Ağırlıklı ve Ağırlıksız Modellerin Sonuçlarının Karşılaştırılması.....	109
Tablo 8 : ESHOT Akıllı Kart Verilerine İlişkin Temel İstatistikler.....	115
Tablo 9: Binişlerin Günün Saat Dilimlerine Dağılımı.....	115
Tablo 10: Binişlerin Hafta İçinde ve Hafta Sonunda Günün Saat Dilimlerine Dağılımı.....	116
Tablo 11: ESHOT Akıllı Kart Verilerinden Bir Kesit.....	117
Tablo 12: Bir Yolcunun Yolculuk Verilerine Örnek.....	126
Tablo 13: Yolcunun Verilerinin Kümeleme Analizine Uygun Formu.....	126
Tablo 14: Temel Bileşenler Analizi Sonuçları.....	127
Tablo 15: Farklı Küme Sayılarına Göre K-Ortalamlar Yönteminin Sonuçları.....	128
Tablo 16: X-Ortalamlar Yöntemine Göre Kart Kullanıcılarının Kümeleme Analizi Sonuçları.....	129
Tablo 17: Aktivasyon Fonksiyonunu Belirlemek için Yapılan Deneylerin Sonuçları.....	133
Tablo 18: Öğrenme Katsayısı ve Momentum için Yapılan Test Sonuçlarının RMSE Değerleri.....	135
Tablo 19: Başlangıç Ağırlıklarının Değer Aralığı İçin Test Sonuçları.....	136
Tablo 20:Yapay Sinir Ağı'nın Sağladığı Tahmin, Hata, Mutlak Hata ve.....	137
Tablo 21: Tahminleme Yöntemlerine İlişkin İstatistikler.....	141
Tablo 22: Kalabalıklık Ölçüsü Olarak $m^2/yolcu$ ve $yolcu/m^2$ Değerleri.....	146
Tablo 23: Optimum Sefer Sıklığı Optimizasyon Modellerinin Birbiri ve Hattın Mevcut Çizelgesiyle Karşılaştırılması.....	147
Tablo 24: Konak Hatlarında Gerçekleşen 30 Günlük Biniş Sayıları.....	158
Tablo 25: Hafta İçi için Tahmin Yöntemlerinin Farklı Servis Zamanları için Karşılaştırılması.....	180
Tablo 26: Hafta Sonu için Tahmin Yöntemlerinin Farklı Servis Zamanları için Karşılaştırılması.....	180
Tablo 27: 63 Nolu Evka 3 Metro – Konak Hattının Hafta Sonu Gidiş Yönü İçin Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	181
Tablo 28: 63 Nolu Evka 3 Metro – Konak Hattının Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	182
Tablo 29: 63 Nolu Evka 3 Metro – Konak hattının Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	183
Tablo 30: 63 Nolu Evka 3 Metro – Konak Hattının Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	184
Tablo 31: 63 Nolu Evka 3 Metro – Konak Hattı için ESHOT'un Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge.....	185
Tablo 32: 802 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	186
Tablo 33: 802 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	187

Tablo 34: 802 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	188
Tablo 35: 802 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	189
Tablo 36: 802 Nolu Egekent Aktarma – Konak Hattı için ESHOT’un Uyguladığı Çizelgeler ile Algoritma Sonucunda Elde Edilen Çizelgeler.....	190
Tablo 37: 171 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	190
Tablo 38: 171 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	192
Tablo 39: 171 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	193
Tablo 40: 171 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	194
Tablo 41: ESHOT’un 171 Nolu Tınaztepe – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge.....	195
Tablo 42: 554 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	195
Tablo 43: 554 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	196
Tablo 44: 554 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	197
Tablo 45: 554 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	198
Tablo 46: ESHOT’un 554 Nolu Narlıdere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge.....	199
Tablo 47: 169 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	200
Tablo 48: 169 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	201
Tablo 49: 169 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	202
Tablo 50: 169 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	203
Tablo 51: ESHOT’un 169 Nolu Narlıdere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge.....	204
Tablo 52: 23 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	204
Tablo 53: 23 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	205
Tablo 54: 23 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	206
Tablo 55: 23 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	207
Tablo 56: ESHOT’un 23 Nolu Narlıdere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge.....	208
Tablo 57: 285 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	209
Tablo 58: 285 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	210

Tablo 59: 285 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	211
Tablo 60: 285 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	212
Tablo 61: ESHOT'un 285 Nolu Narlidere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge.....	213
Tablo 62: 193 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	213
Tablo 63: 193 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	214
Tablo 64: 193 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	215
Tablo 65: 193 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	216
Tablo 66: ESHOT'un 193 Nolu Narlidere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge.....	217
Tablo 67: 18 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	218
Tablo 68: 18 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	219
Tablo 69: 18 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	220
Tablo 70: 18 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	221
Tablo 71: ESHOT'un 18 Nolu Narlidere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge.....	222
Tablo 72: 465 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	222
Tablo 73: 465 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	223
Tablo 74: 465 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	224
Tablo 75: 465 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları.....	225
Tablo 76: ESHOT'un 465 Nolu Narlidere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge.....	226
Tablo 77: Model 3 için Önerilen Basit Algoritma ve Genetik Algoritma Sonuçları	230
Tablo 78: Model 6 için Önerilen Basit Algoritma ve Genetik Algoritma Sonuçları	230
Tablo 79: Model 9 için Önerilen Basit Algoritma ve Genetik Algoritma Sonuçları	231
Tablo 80: Model 12 için Önerilen Basit Algoritma ve Genetik Algoritma Sonuçları	231
Tablo 81: Model 13 için Önerilen Basit Algoritma ve Genetik Algoritma Sonuçları	232
Tablo 82: Model 14 için Önerilen Basit Algoritma ve Genetik Algoritma Sonuçları	232
Tablo 83: Vuchic'in Bağıntısından Elde Edilen Sonuçlar	233
Tablo 84: Optimizasyon Modellerinin Toplu Sonuçları	234

ŞEKİLLER LİSTESİ

Şekil 1 : Ulaşım Ana Planı Çalışmasının Akış Şeması, Acil Eylem Planları ve Raylı Sistem Projeleri Arasındaki İlişki	8
Şekil 2: Akıllı Kart Kullanıcılarının Biniş Durağından İniş Durağına Tahminlenme Süreci.....	27
Şekil 3: Öklid Mesafesi.....	29
Şekil 4: Manhattan Mesafesi.....	30
Şekil 5: Küresel Üçgen.....	32
Şekil 6: Maksimum Hat Talebinin Belirlenmesi.....	41
Şekil 7: Veri Tabanından Bilgi Keşfi Süreci (VBTK).....	62
Şekil 8: Veri Küplerine Bir Örnek	66
Şekil 9: En Kısa Mesafenin Hataya Neden Olabileceği Özel Durumlar	73
Şekil 10: İleri Beslemeli Bir Yapay Sinir Ağı Modeli.....	75
Şekil 11: Doğal ve Yapay Sinir Hücresi	77
Şekil 12: İleri ve Geri Beslemeli Yapay Sinir Ağları	81
Şekil 13: Öğrenme Yöntemlerine Göre Yapay Sinir Ağları	81
Şekil 14: Basit Bir Genetik Algoritmanın Evrimleşme Süreci	93
Şekil 15: $\zeta=0.67$, $\alpha=1.5$ ve $\beta=4$ Karma Dağılımın Görünümü.....	105
Şekil 16: Otobüs Sefer Sürelerinin Dağılımı	106
Şekil 17: Sefer Sıklığı Optimizasyonu için Önerilen Algoritmanın Akış Şeması ...	107
Şekil 18: Hafta İçi Akıllı Kart Kullanımlarının Dağılımı	122
Şekil 19: Hafta Sonu Akıllı Kart Kullanımlarının Dağılımı	123
Şekil 20: 15 Günlük Akıllı Kart Verilerinin Genel Dağılımı.....	123
Şekil 21: Biniş ve İniş Hareketlerinin Otogar - Konak Hattının Gidiş Yönündeki Duraklarına Dağılımı	124
Şekil 22: Biniş ve İniş Hareketlerinin Otogar - Konak Hattının Dönüş Yönündeki Duraklarına Dağılımı	125
Şekil 23: Temel Bileşenler Analizi Saçılma Grafiği (Scree Plot).....	127
Şekil 24: Mahalonobis Uzaklığı ve $K=3$ İçin K-Ortalamalar Yöntemine Göre Kart Kullanıcılarının Kümeleme Dağılımı.....	129
Şekil 25: Cosine Uzaklığı ve $K=4$ İçin X-Ortalamalar Yöntemine Göre Kart Kullanıcılarının Kümeleme Dağılımı.....	130
Şekil 26: Geliştirilen yapay sinir ağının yapısı	131
Şekil 27: Gizli Katmandaki Sinir Hücreleri Sayısının Belirlenmesi.....	133
Şekil 28: Hareketli Ortalamalar Yöntemi ve Yapay Sinir Ağı ile Yapılan Tahminler	138
Şekil 29: Ağırlıklı Hareketli Ortalamalar Yöntemi ve Yapay Sinir Ağı ile Yapılan Tahminler	139
Şekil 30: Üstel Düzeltme Yöntemi ve Yapay Sinir Ağı ile Yapılan Tahminler	139
Şekil 31: Çoklu doğrusal regresyon analizi ve Yapay Sinir Ağı ile Yapılan Tahminler	140
Şekil 32: Pozitif Sapmaların Ağırlık Katsayısının Sefer Sıklığına ve Bekleme Sürelerine Etkisi	149
Şekil 33: Pozitif Sapmaların Ağırlık Katsayısının Maliyet ve m^2 'ye Düşen Yolcu Sayısına Etkisi.....	150
Şekil 34: Yolcu Bekleme Süresi Ağırlık Katsayısının Sefer Sıklığına ve Bekleme Sürelerine Etkisi	151
Şekil 35: Yolcu Bekleme Süresi Katsayısının Maliyete ve m^2 'ye Düşen Yolcu Sayısına Etkisi.....	151

Şekil 36: Maliyet Ağırlık Katsayısının Sefer Sıklığına ve Bekleme Sürelerine Etkisi	152
Şekil 37: Maliyet Ağırlık Katsayısının Maliyete ve m ² 'ye Düşen Yolcu Sayısına Etkisi	152
Şekil 38: m ² 'ye Düşen Yolcu Sayısı Ağırlık Katsayısının Sefer Sıklığı ve Yolcuların Bekleme Süresine Etkisi	153
Şekil 39: m ² 'ye Düşen Yolcu Sayısı Ağırlık Katsayısının Maliyete ve m ² 'ye Düşen Yolcu Sayısına Etkisi	154
Şekil 40: Tek Noktalı Permütasyon Çaprazlama Operatörünün İşleyişi	156
Şekil 41: 63 Nolu Evka 3 Metro – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	159
Şekil 42: 63 Nolu Evka 3 Metro – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı.....	159
Şekil 43: 63 Nolu Evka 3 Metro – Konak Hattında Talebin Zamana Göre Dağılımı	160
Şekil 44: 802 Nolu Egekent Aktarma – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	161
Şekil 45: 802 Nolu Egekent Aktarma – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	161
Şekil 46: 802 Nolu Egekent Aktarma – Konak Hattında Talebin Zamana Göre Dağılımı	162
Şekil 47: 171 Nolu Tınaztepe – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	163
Şekil 48: 171 Nolu Tınaztepe – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	163
Şekil 49: 171 Nolu Tınaztepe – Konak Hattında Talebin Zamana Göre Dağılımı..	164
Şekil 50: 554 Nolu Narlıdere – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	165
Şekil 51: 554 Nolu Narlıdere – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	165
Şekil 52: 554 Nolu Narlıdere – Konak Hattında Talebin Zamana Göre Dağılımı...	166
Şekil 53: 169 Nolu Balçova – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	167
Şekil 54: 169 Nolu Balçova – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	167
Şekil 55: 169 Nolu Balçova – Konak Hattında Talebin Zamana Göre Dağılımı	168
Şekil 56: 23 Nolu Uzundere – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	169
Şekil 57: 23 Nolu Uzundere – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	169
Şekil 58: 23 Nolu Uzundere – Konak Hattında Talebin Zamana Göre Dağılımı	170
Şekil 59: 285 Nolu Evka 1 – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	171
Şekil 60: 285 Nolu Evka 1 – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	171
Şekil 61: 285 Nolu Evka 1 – Konak Hattında Talebin Zamana Göre Dağılımı	172
Şekil 62: 193 Nolu Yurtoğlu – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	173
Şekil 63: 193 Nolu Yurtoğlu – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	173

Şekil 64: 193 Nolu Yurtoğlu – Konak Hattında Talebin Zamana Göre Dağılımı ...	174
Şekil 65: 18 Nolu Yeşilyurt – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	175
Şekil 66: 18 Nolu Yeşilyurt – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	175
Şekil 67: 18 Nolu Yeşilyurt – Konak Hattında Talebin Zamana Göre Dağılımı.....	176
Şekil 68: 465 Nolu Tınaztepe – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	177
Şekil 69: 465 Nolu Tınaztepe – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı	177
Şekil 70: 465 Nolu Tınaztepe – Konak Hattında Talebin Zamana Göre Dağılımı..	178
Şekil 71: Genetik Algoritma Popülasyon Büyüklüğünün Algoritma Uygunluk Değerine Etkisi.....	227
Şekil 72: Çaprazlama Oranının Genetik Algoritma Uygunluk Değerine Etkisi	228
Şekil 73: Mutasyon Oranının Genetik Algoritma Uygunluk Değerine Etkisi	228
Şekil 74: Bireyde Mutasyona Uğrayan Gen Sayısının Genetik Algoritma Uygunluk Değerine Etkisi.....	229

EKLER

EK 1: Geliştirilen Yazılımdan Ekran Görüntüleri	279
EK 2: Otogar-Konak Hattı Hesaplanan Talep Düzeyleri	280
EK 3: Aktarmalı Binişlerden Tespit Edilen İniş Duraklarına Örnekler	281
EK 4: Sabah ve Akşam Binişlerinden İniş Durağı Tespitine Örnekler	283
EK 5: Diker'in Rastgele Atama Tahmın Yöntemine Göre Belirlenen İniş Duraklarına Örnek	285
EK 6: Hattın Son Durağının İniş Durağı Olarak Atandığı Örnekler	287



GİRİŞ

Günümüz Türkiye'sinde şehir içi toplu taşıma hizmetleri yerel yönetimlerin görevi olarak kabul edilmektedir. Bu nedenle her ilde belediyeler şehir içi ulaşımı sağlamak amacıyla otobüs, tren, metro, tramvay vb. ulaşım araçlarının hatlarını ve seferlerini planlayan ve uygulayan işletmeler kurmuşlardır.

Bu işletmeler gelecekteki faaliyetlerini düzenlemek için stratejik düzeyde uzun vadeli (15 – 20 yıllık) ulaşım ana planını, taktiksel düzeyde orta veya kısa vadeli (1 – 3 yıl) acil eylem ulaşım ve trafik iyileştirme planını oluştururlar.

Bir kentte gerek araçlar ile gerekse yaya olarak bir yerden bir yere hızlı ve güvenli bir şekilde ulaşmak, mevcutta var olan sorun ve darboğazları çözüme kavuşturmak, şehrin fiziksel ve kültürel olarak gelişmesine ulaşım ve trafik şartlarını da sağlıklı ve verimli bir şekilde entegre etmek maksadı ile yapılan stratejik seviyedeki çalışmaların bütününe Ulaşım Ana Planı denmektedir (Türkiye Belediyeler Birliği, 2014: 12). Ulaşım ana planı dört aşamada gerçekleştirilir. İlk aşama yolculuk üretimidir (Trip Generation) ve şehir genelinde yapılan bölgelemeye göre her bölgenin ne sayıda yolculuk üreteceği tahmin edilmeye çalışılır. Bu aşamada yolculuğun başlangıç yeri olarak kabul edilen her bir bölgede hane halkı geliri, hane halkında çalışan kişi sayısı, taşıt sahipliği gibi çeşitli değişkenler dikkate alınarak yolculuk sayısı hesaplanır. İkinci aşama yolculuk dağılımıdır (Trip Distribution) ve her bölgede başlayan ve önceki aşamada belirlenmiş yolculukların hangi bölgelere gideceği modelleme ile tahmin edilir. Böylece başlangıç ve varış bölgeleri arasında yolculukların dağılımı modellenir. Üçüncü aşama türel dağılımdır (Modal Split) ve yolculukların ne oranda toplu taşıma ile ne oranda özel araç ile yapılacağı tahmin edilmeye çalışılır. Dördüncü aşama olan trafik ataması (Traffic Assignment) aşamasında tahmin edilen yolculukların güzergah seçimi konusunda tahminler yapılmaya çalışılır. Yolculuk süresini en az yapacak seçimler yapılacağı varsayımı ile modeller geliştirilir ve uygulanır. Ulaştırma planlamacıları, ikinci aşamadaki başlangıç –varış bölgeleri arasında yolculukların dağılımını belirlemek amacıyla anket uygulayarak veya trafik sayımları yaparak bölge bazında başlangıç-varış matrislerini tahmin etmeye çalışırlar. Bu matrisler yardımıyla bütün hatlar için talebi tahmin ederek yeni yatırımlarını gerçekleştirirler. Gelecek öngörüsü için bu yöntemler tek başına yeterli değildir. Bu yöntemlerin yanı sıra literatürde ilin nüfus yapısı ve bu yapıdaki değişim, doğum, ölüm ve göç oranları, gelir düzeyleri ve dağılımı, ildeki taşıt sahipliği

gibi faktörleri veri olarak kullanan regresyon modelleri veya YSA uygulamaları da görülebilir.

“Acil Eylem Ulaşım ve Trafik İyileştirme Planı ulaşım sisteminin mevcut yapı ve özellikleri konusunda toplanan bilgilerin değerlendirilmesi neticesinde, ulaşım sistemindeki aksaklık ve darboğazların belirlenmesi ve bu sorunların giderilmesi için kısa dönemde (1 – 3 yıl) uygulanabilecek ulaşım ve trafik planlaması, yönetimi, trafik mühendisliği çözümlerini kapsar (Türkiye Belediyeler Birliği, 2014: 12).

Ulaşım ücretlendirmesinde akıllı kart kullanımı ve coğrafi konumlama sistemleri (Global Positioning System - GPS) ulaşım planlaması için önemli bir veri kaynağı oluşmasını sağlamıştır. Büyük veri tabanlarında saklanan biniş verileri zamansal ve mekansal yolcu davranış kalıplarını anlamaya yardımcı olma potansiyeline sahiptir. Ayrıca araçların duraklara varış zamanları incelenerek sefer çizelgelerine ne ölçüde uyulduğunu gösteren güvenilirlik düzeyi gibi performans ölçütleri hesaplanabilir. Bu veritabanlarında biriken büyük verinin doğru veri madenciliği algoritmaları ile analiz edilerek faydalı veriler elde edilebileceğinin anlaşılması hem sektörde çalışan planlama uzmanları hem de üniversitelerde çalışan akademik personelin bu konuya yoğun ilgi göstermesini sağlamıştır. Bu konuda yabancı literatürde çok sayıda çalışma olduğu gözlenmiştir, ülkemizde ise 3 tez, 5-6 tane makale tespit edilebilmiştir. Yerli literatürde bu konularda daha fazla çalışma yapılmasına ihtiyaç vardır.

Ulaşımında yeni bir teknoloji olan akıllı kart verilerinde çoğu sistemde sadece biniş verisi yer almaktadır. Bu nedenle bu alandaki ilk çalışmalar bazı varsayımlara dayanan biniş duraklarından iniş duraklarının tahminine yönelik algoritmalar geliştirmek olmuştur. Daha yeni bazı sistemlerde Radyo Frekans Tanıma (Radio Frequency Identification – RFID) teknolojisi kullanıldığı için kartı göstermeye gerek kalmaksızın iniş doğrulaması yapılabilmektedir. Bu sistemlerde hem biniş hem iniş verileri bulunduğundan başlangıç – varış (BV) matrislerinin durak bazında hesaplanması daha kolaydır. Başlangıç – varış matrisleri oluşturulunca araç yük profilleri, maksimum hat talebinin tahmini, tüketicilerin davranışsal analizi vb. planlama faaliyetleri gerçekleştirilebilmektedir.

Bu çalışmada ulaşım planlamasında akıllı kart ve GPS verilerinin ne şekilde kullanılabileceğine bir örnek teşkil etmesi için biniş duraklarından iniş duraklarını tahminleyen, durak seviyesinde başlangıç – varış matrislerini oluşturan, veri setindeki her günün her zaman dilimi için maksimum talebi hesaplayan ve bu talep bilgileriyle

gelecek öngörüsü yapan, hat parametreleri (hat uzunluğu, hatta kullanılan körüklü ve solo otobüs sayıları, ortalama ulaşım süresi vb.) ve tahmin edilen talep düzeyi için günün belirli bir zamanında optimum sefer sıklığını hesaplayan bir yazılım geliştirilmiştir. Bu çalışmanın temel amacı ulaştırma planlamacılarına biriken akıllı kart verilerinin değerini, o verilerden faydalı verileri nasıl elde edebileceklerini gösterebilmektir.

Çalışmanın birinci bölümünde ulaşım planlaması ve ulaşım planlamasında akıllı kart verilerinin kullanımına ilişkin çalışmaları inceleyen bir literatür araştırması sunulmuştur. Bu bölümde kısa ve uzun vadeli planlama süreci açıklanmış, bu planlama faaliyetleri için veri toplama yöntemleri ele alınmıştır. Ulaşım planlamasında akıllı kart kullanımına ilişkin literatürde rastlanan uygulama örneklerine yer verilmiştir. Bölümde ayrıca başlangıç – varış matrisi tahmini ve talep düzeyinin hesaplanması da gösterilmiştir.

İkinci bölümde veri madenciliği, uygulama alanları, kullanılan yöntemler ile performans ölçüm metrikleri ve veri madenciliği sürecinde yer alan adımlar açıklanmıştır. Bu bölümde veri madenciliği hakkında kısa bir literatür özeti yer almaktadır.

Üçüncü bölümde uygulamada kullanılan her algoritma için bir literatür özeti sunulmuştur. İlk olarak biniş duraklarından iniş duraklarını ve başlangıç – varış matrisini tahminleme için yapılmış çalışmalar özetlenmiştir. İkinci olarak yapay sınır ağları kısaca tanıtılmış ve bu alandaki gelişmeler kısa bir literatür özeti ile gösterilmiştir. Ardından genetik algoritma tanıtılmış ve tarihsel gelişim süreci hakkında bir literatür özeti sunulmuştur. Son olarak optimum sefer sıklığını hesaplayan basit bir algoritmik yaklaşım önerisi sunulmuştur.

Dördüncü bölümde ESHOT Genel Müdürlüğü'nün izni ile Ulaşım Planlama Dairesi Başkanlığı'ndan elde edilen verilerden iniş duraklarını, BV matrisini tahmin eden, Yapay sınır ağı (YSA) ile günün herhangi bir zaman dilimi için gelecek öngörüsü yapan ve belirli bir hat için o zaman diliminde olması gereken optimum sefer sıklığını hem işletme hem tüketici ihtiyaçlarını gözetten matematiksel modeller yardımıyla hesaplayan bir yazılım prototipi geliştirilmiştir. Prototip Otogar – Konak hattı üzerinde geliştirilmiş ve test edilmiştir. Daha sonra Konak bağlantılı en yoğun 10 hat belirlenmiş ve geliştirilen yazılım bu 10 hat için çalıştırılarak test edilmiştir. Test sürecinde yolculuk zincirleme algoritmasının iniş duraklarının % 5868'ini tahmin edebildiği, Diker'in rastgele atama tahmin yönteminin iniş duraklarının yaklaşık %

37,63'ünü tahmin edebildiği görülmüştür. Kalan iniş durakları incelenen hattın incelenen yöndeki en son durağı olarak belirlenmiştir. Algoritma biniş ve iniş durakları yardımıyla durak seviyesinde BV matrisinin her gün ve günün her saati için hesaplayıp o zaman dilimindeki maksimum hat talebini hesaplamıştır. Bu veriler kullanılarak hafta içi ve hafta sonu gidiş ve dönüş yönleri için talep tahminleri yapan YSA'lar eğitilmiştir. Gelecek öngörüsü için bu YSA'lar hareketli ortalamalar, ağırlıklı hareketli ortalamalar, üstel düzeltme ve regresyon yöntemleri ile karşılaştırılmıştır. YSA'ların diğer yöntemlere göre çok daha düşük bir hata ile tahmin yapabildiği görülmüştür. Hedef programlama formülasyonunda 14 farklı matematiksel model oluşturulmuş, önerdiğimiz algoritmik yöntem ve genetik algoritma ile çözümü yapılmıştır. Her iki algoritmanın optimum sonuçları verdiği görülmüştür.



BİRİNCİ BÖLÜM

TOPLU TAŞIMA PLANLAMASI ve AKILLI KART VERİLERİ

KULLANIMI

Çalışmanın bu bölümünde toplu taşıma planlaması ve bu planlama sürecinde akıllı kart verilerinin kullanımı, jeodezik mesafe ölçüleri, başlangıç – varış matrislerinin tahminlenmesi ve sefer sıklığı optimizasyonu hakkında kısa bir literatür özeti sunulmuştur.

1.1. TOPLU TAŞIMA PLANLAMASI

Toplu taşıma sistemleri, insanların, malların, fikirlerin ve bilgilerin hareketi, toplumun gelişimi için temel olmuştur. Denizyolu, kanallar, bisikletler, demiryolları, motorlu kara taşıtları ve uçakların her biri ekonomik ve sosyal gelişimi önemli düzeyde etkilemiştir (Cowie, 2010’dan aktaran Gudmundsson vd., 2010: 51). Bu nedenle şehirlerin ve toplumun gelişebilmesi için etkin ve sürdürülebilir bir ulaşım ağı oluşturulmalıdır.

“Ulaşım planlaması karar vericilerin gelecekteki ulaşım sistemlerinin gelişmelerine ait kararları verebilmelerine yardımcı olacak bilgileri geliştiren bir süreçtir. Ulaşım planlaması, kentsel ulaşım altyapısında mevcut durum analiz ve değerlendirmelerinin yapıldığı, gelecek zaman (hedef yıl ve/veya yıllar) için yatırımların, düzenlemelerin ve işletme yaklaşımlarının belirlendiği, öngörülerin elde edildiği sürdürülebilir planlama yaklaşımı için bir araç veya yöntem olarak tanımlanabilir” (Türkiye Belediyeler Birliği, 2014: 6).

Ulaşım planlaması, insanların ve malların hareket taleplerine ilişkin sorunların analizi ve toplumun isteklerine uygun olarak sürdürülebilir erişilebilirliği sağlamak için uygun çözümlerin belirlenmesi amacıyla gerekli tüm faaliyetleri kapsar. Kentsel ulaşım planlamasının temel amaçları: 1) şehir bölgesi için uyumlu bir sistem oluşturacak ve yaşam kalitesini arttıracak verimli, ekonomik, çevreye duyarlı ulaşım tesislerinin kurulması, 2) sistemin farklı bileşenlerini koordineli bir şekilde çalıştırmak için etkin bir mekanizma geliştirilmesi ve 3) planın bölgenin uzun vadeli ihtiyaçlarını karşılaması sağlanırken, aynı zamanda kısa ve orta vadeli bileşenleri de karşıladığından emin olunmasıdır (Victor ve Ponnuswamy, 2012: 34).

Ulaştırma planlama süreci aşağıdaki varsayımlara dayanmaktadır (Victor ve Ponnuswamy, 2012: 34):

- 1) Yolculuk deseni somut, öngörülebilir ve sabittir;
- 2) Ulaştırma sistemi bir bölgenin gelişimini etkiler ve bölgedeki gelişimden etkilenir;
- 3) Tüm ulaştırma modlarının aralarında kesin bir ilişki vardır. Bu nedenle, bölgedeki herhangi bir modun gelecekteki rolü izole edilerek düşünülemez;
- 4) Komşu kentleşme alanları, sorunların bölgesel bazda dikkate alınmasını gerektirir;
- 5) Ulaştırma planlaması tasarlama, uygulama, izleme, güncelleme, doğrulama ve düzeltici önlemleri almayı içeren sürekli bir süreçtir.

Bir bölgedeki arazi kullanımı yolculuk düzenini çok etkiler, bu nedenle ulaşım tesislerine olan talebi etkiler. Aynı zamanda mevcut ulaşım altyapısı arazi kullanım düzenini etkiler. Bu nedenle, ulaşım planlaması, bölge için genel planlama sürecinin ayrılmaz bir parçasını oluşturmak zorundadır (Victor ve Ponnuswamy, 2012: 34).

Ulaşım planlamacıları günümüzde çeşitli faaliyetlere yönelik çalışmalar yapmaktadır. Bu faaliyetler: ulaştırma sistemlerinin gelişimi için ayrılan kaynakların verimli kullanımının planlanması, trafik sıklığının azaltılması ve talep yönetimi, tür ve güzergah seçimini etkileyen faktörlerin belirlenmesi, toplu taşımanın özendirilmesi, yolcular için güvenli ve konforlu sistemler oluşturulması, gürültü ve hava kirliliğinin azaltılması, toplu taşımada optimizasyon, türler arası entegrasyonun akılcı ve uygulanabilir olması şeklinde özetlenebilir (Türkiye Belediyeler Birliği, 2014: 6).

Türkiye’de ulaşım planlaması çalışmaları 3 ana başlık altında toplanabilir: ulaşım ana planının hazırlanması, acil eylem ulaşım ve trafik iyileştirme plan, etüt ve projelerinin hazırlanması, raylı sistem/metrobüs/kablolu sistem hatları ön/kesin projeleri ve fizibilite etütlerinin hazırlanması (Türkiye Belediyeler Birliği, 2014: 12).

1.1.1. Ulaşım Ana Planı

“Bir kentte gerek araçlar ile gerekse yaya olarak bir yerden bir yere hızlı ve güvenli bir şekilde ulaşmak, mevcutta var olan sorun ve darboğazları çözüme kavuşturmak, şehrin fiziksel ve kültürel olarak gelişmesine katkı sağlamak, ulaşım ve trafik şartlarını da sağlıklı ve verimli bir şekilde entegre etmek maksadı ile yapılan

stratejik seviyedeki çalışmaların bütününe Ulaşım Ana Planı denmektedir” (Türkiye Belediyeler Birliği, 2014: 12).

Kentlerde hızla artan nüfus, işgücü, iş alanlarının genişlemesi, artan özel araç sahipliği, kentsel kullanım alanlarının genişlemesi ve çeşitlenmesi gibi etkenler, günümüzde önemli bir sorun olan kentiçi ulaşımın çevre, enerji, sürdürülebilirlik, sosyal denge gibi konular dikkate alınarak bilimsel yöntemlerle çözümlenmesi ve düzenlenmesini gerekli kılmaktadır (Türkiye Belediyeler Birliği, 2014: 12).


Belediyelerin uzun vadeli ulaşım planlarında; hedef yıllar içinde arazi kullanım ve nüfus yapısına bağlı olarak, ekonomik açıdan düşük maliyetli ve kentin planlı gelişimine katkı sağlayan; ekolojik açıdan çevreye verdiği zararı minimuma indiren; toplumsal açıdan sosyal eşitlik ilkesine bağlı, kentin tarihi ve kültürel kimliği ile uyumlu, erişilebilirlik, konfor, güvenlik, güvenilirlik gibi nitelikleri içeren, sürdürülebilir bir ulaştırma sisteminin kurulması ile kentte yaşayanların ulaşım taleplerinin karşılanması amaçlanmalıdır (Türkiye Belediyeler Birliği, 2014: 12).

Hazırlanacak Ulaşım Ana Planı, mevcut ve gelecek kentiçi ve yakın çevre ulaşım sorunlarına kısa, orta, uzun vadede, akılcı ve uygulanabilir çözüm bulma amacıyla nazım imar planı hedef yılı baz alınarak oluşturulacak ve kent nazım imar planına uyumlu ulaşım gelişmelerini yönlendirecek, uzun dönemli ulaşım yatırımlarını, politikalarını, plan ve projelerini kapsayan ulaşım sistemini ortaya koyacak şekilde (15-20 yıl) belirlenmelidir (Türkiye Belediyeler Birliği, 2014: 14).

1.1.1.1. Ulaşım Ana Planı Yapım Aşamaları

Ulaşım ana planı yedi temel aşamada gerçekleşir: mevcut bilgilerin toplanması ve değerlendirilmesi, yeni bilgilerin toplanması ve değerlendirilmesi, ulaşım talep tahmin modeli kalibrasyonu ve doğrulaması, hedef yılı girdi tahminleri, yetersizlik analizi, alternatif toplu taşıma tür planlarının geliştirilmesi ve ulaşım modeliyle test edilmesi, seçilen alternatifin ulaşım ana planı olarak hazırlanması. Ulaşım ana planı çalışmasının akış şeması, acil eylem planları ve raylı sistem projeleri arasındaki ilişki Şekil 1’de gösterilmiştir.

Şekil 1 : Ulaşım Ana Planı Çalışmasının Akış Şeması, Acil Eylem Planları ve Raylı Sistem Projeleri Arasındaki İlişki



Kaynak: Türkiye Belediyeler Birliği, 2014: 14.

Mevcut Bilgilerin Toplanması ve Değerlendirilmesi

Bilgi toplama aşamasından önce çalışmanın yürütüleceği alan sınırı belirlenir. Çalışma alanı önce bölgelere daha sonra “zon” adı verilen planlama birimlerine ayrılır. Zon büyüklükleri ve sayısı çalışma bütçesine, veri toplama için ayrılan süreye ve istenen ayrıntı düzeyine göre saptanır. Zonlama sonrasında çalışma yapılacak alan ön araştırma ile yakından tanınmaya çalışılır. Bu aşamada bölge ve zonlardaki, kavşak kapasiteleri, yoğun ve tenha yollar, otopark alanları ve ihtiyaçları, hastane, iş merkezi, AVM vb. trafik çeken yapılar, trafiğin sıkışmasına neden olan düğüm-geçit noktaları tespit edilmelidir. Ön araştırmadan sonra dış kordon hattı belirlenir. Dış kordon araştırma yapılacak alanın dış sınırıdır (Kılınçaslan vd., 2017: 214 – 215).

Çalışma alanı ve zonlar belirlendikten sonra kent yapısı incelenmelidir. Yolculuk talebini arazi kullanım örüntüsü, yolcuların sosyo – ekonomik özellikleri ve ulaşım sisteminin mevcut özelliklerinin etkileyeceği kabul edilir. Ulaşım araştırmalarında iskan alanları, çalışma alanları (ticaret ve sanayi), eğitim ve rekreasyon alanları talebi önemli olarak etkilediklerinden dikkate alınırlar. Her zonda çeşitli meslek ve gelir grubundaki yolcular farklı talep modelleri oluştururlar. Gelir arttıkça hareketlilik ve özel araç kullanımı artar, alışveriş ve eğlence yerlerine doğru ulaşım talebi artar. Gelir azaldıkça toplu taşıma kullanımı ve yaya trafiği artar. Talebi

etkileyen önemli bir unsurda ulaşım sisteminin özellikleri, hizmet düzeyi ve yeterliliğidir. (Kılınçaslan vd., 2017: 218 – 219).

Bu iş kapsamında, çeşitli resmi ve özel kurumlarda mevcut olan bilgiler toplanır ve bu bilgiler değerlendirilerek, eksiklikleri, tutarsızlıkları ve güncelleştirilmesi gerekenleri belirlenir. Kentin geçmişteki özelliklerinin yanı sıra mevcut yapısının açıklanmasına yardımcı olacak nüfus, iş gücü, gelir dağılımı, oto sahipliği, arazi kullanımı, gelişme eğilimleri gibi demografik, sosyoekonomik ve mekânsal veriler ile planlanan ve devam eden proje ve yatırımlara ilişkin bilgiler kamu ve özel kuruluşlardan toplanılabilecektir. Kentin ulaşım yapısını ve özelliklerini tanımlamak için gerekli olan kent içi ve kentler arası, kentle çevre yerleşimler arası ulaşım bilgileri merkezi ve yerel kamu kuruluşlarından ve özel sektör kaynaklarından elde edilmelidir. Bu çerçevede orta ve uzun vadede kent dışı ve kent içi yük ve yolcu hareketleri, yük cinsleri, yolculuk türleri, başlangıç ve bitiş noktaları gibi bilgiler toplanmalıdır (Türkiye Belediyeler Birliği, 2014: 18).

Toplanan bu veriler bir araya getirilerek bir veritabanına kaydedilmelidir. Veritabanına kaydedilirken verilerdeki tutarsızlık ve eksiklikler giderilmelidir. Toplanan bu veriler bir rapor haline getirilmeli, değerlendirilmeli analiz edilmelidir.

Yeni Bilgilerin Toplanması

Kentiçi yolculuk yapısının anlaşılmasına yönelik olarak nüfusun, iş gücünün, işyeri dağılımının, diğer sosyoekonomik değişkenlerin, ulaşım türlerinin (özel araç, toplu taşıma, servis vb.) belirlenmesi gibi ilave bilgilerin güncel olarak toplanması gerekir (Türkiye Belediyeler Birliği, 2014: 19).

Toplanan eski ve yeni bilgiler veritabanında bir araya getirilir, tutarlılık ve güvenilirlikleri sağlanır. Eksiklikleri tamamlanmış ve güncelleştirilmiş bu bilgiler ışığında kentin ulaşım yapısı, araç ve yolcu hareketlerinin özellikleri ortaya çıkartılıp yorumlanır ve değerlendirilir (Türkiye Belediyeler Birliği, 2014: 20).

Yeni bilgi toplama için kullanılan yöntemlerden bazıları: hane halkı ulaşım anketleri, yurt anketleri, karayolu trafik sayımları, dış istasyon anketleri, karayolu alt yapı envanteri, karayolu ve toplu taşıma hız etütleri, bisikletli ve motosikletli anketleri, yaya anketleri, otopark anketleri vb.'dir (Türkiye Belediyeler Birliği, 2014: 20).

Verilerin Analizi ve Model Girdilerinin Hazırlanması

Toplanan veriler istatistiksel ve bilimsel yöntemlerle analiz edilerek değerlendirilmelidir. Çalışma kapsamındaki alan öncelikle, trafik analiz bölgesi adı verilen trafik üreten veya çeken coğrafi bölümlere ayrılmalıdır. Trafik analiz bölgeleri oluşturulurken mahalle nüfus, işgücü vb. verilerden yararlanılmalıdır (Türkiye Belediyeler Birliği, 2014: 22).

Kullanılacak ulaşım modellerinde, kentte halen işletilmekte olan toplu taşıma ve ara toplu taşıma sistemleri (metro, hafif raylı sistem, tramvay, kablolu insan taşıma sistemleri, otobüs, dolmuş, taksi ve servis araçları vb.) ile yapımı devam eden raylı sistem vb. toplu taşıma hatları ve varsa deniz ulaşımı da (yolcu vapuru, deniz otobüsü, feribot vb.) göz önüne alınmalıdır. Mevcut toplu taşıma sistemlerine ilişkin hatlar, güzergahlar, durak/istasyon/iskele ve terminaller, sabah ve akşam doruk saatlerdeki sıklıklar, hızlar, bilet ücretleri model girdisi formatında değerlendirilmelidir (Türkiye Belediyeler Birliği, 2014: 23).

Bu aşamada gelecekte kent yapısında meydana gelecek yeni değişimler belirlenmelidir. Bu değişimlerin öngörülmesi için nüfus ve yoğunluk, ekonomik faaliyetler, arazi kullanımı, ulaşım sistemi değişim verileri incelenerek mevcut eğilimler değerlendirilmelidir (Kılınçaslan vd., 2017: 234).

Yolculuk Talep Tahmin Modelinin Kurulması ve Kalibrasyonu

Gelecekteki ulaşım sisteminin özelliklerinin tahmininde kullanılacak modelin kurulması ve baz yılı değerlerine göre kalibrasyonu sırasında aşağıdaki işlemler gerçekleştirilmektedir.

Yolculuk Üretim/Çekim

Yolculuk üretim/çekim tabloları için gerekli nüfus, iş gücü, öğrenci ve hastane yatak bilgileri, Türkiye İstatistik Kurumu (TÜİK) verilerinin yanı sıra gerek belediyeden, gerekse diğer ilgili kurum ve kuruluşlardan sağlanacak bilgiler ve konut (hanehalkı) anketlerinden elde edilmektedir. Ulaşım modellerinin ilk aşaması olan yolculuk üretim/çekim modellerinde her bir trafik analiz bölgesinden üretilen/çekilen yolculuklar bu bölgelerin nüfus, istihdam, öğrenci sayıları, hastanelerdeki yatak

sayıları, nüfusun gelir düzeyi, sosyoekonomik vb. parametrelere bağlı olarak hesaplanır (Türkiye Belediyeler Birliği, 2014: 23).

Yolculuklar amaçlarına göre:

- a) Ev-İş yolculukları
- b) Ev-Okul yolculukları
- c) Ev-Diğer yolculukları
- d) Ev Uçlu Olmayan (Diğer) Yolculuklar

olmak üzere en az dört gruba ayrılır, her yolculuk amacı için bölgelerde oluşturulan ve çekilen günlük yolculuklar hesaplanır. Yolculuk üretim ve çekiminin değerlendirilmesinde gelir durumu ve grupları dikkate alınmalıdır (Türkiye Belediyeler Birliği, 2014: 23).

Yolculuk üretim/çekim modellemesinde büyüme faktörü, akıllı büyüme faktörü, çoklu doğrusal regresyon analizi, çapraz sınıflandırma (kategori analizi), olasılıklı seçim ve ayırık seçim modelleri kullanılmaktadır.

Yolculuk Dağıtımı

Model toplu taşıma trafiği için bir paylaştırma modeli olarak tasarlanmış olmalı ve bu model, ulaşım zamanlarını, bekleme sürelerini, aktarma sürelerini ve frekanslarını dikkate alarak en uygun güzergahlara dağıtımını yapmalı, güzergah yükleri ve duraklardaki hacimleri oluşturabilmelidir. Model bütün güzergahlar üzerindeki yolculuk zamanlarını minimize etmeli, başlangıç ve varış arasındaki bütün yolculuk ilişkilerini olası güzergahlara dağıtmalıdır (Türkiye Belediyeler Birliği, 2014: 24).

Yolculuk dağıtımını modelinde yolculuk üretim/çekim modeli ile tahmin edilen yolculuklar bölgeler arasında bölüştürülerek her yolculuk amacı için başlangıç – varış matrisleri oluşturulur (Türkiye Belediyeler Birliği, 2014: 24).

Kalibrasyon sırasında modelden elde edilen yolculuk matrisi, anketlerle belirlenmiş olan gözlem matrisine yeterince yakın olana kadar ardışık işlemler yapılarak, model ve gözlem matrislerinin uygunluğu hem matrislerin başlangıç – varış değerlerinin yakınlığı, hem de iki matristen elde edilen yolculuk uzunluğu dağılımlarının uyumu ile kontrol edilecektir (Türkiye Belediyeler Birliği, 2014: 24).

Yolculuk Dağıtımında tekdüze faktör (uniform factor), Detroit, ortalama faktör, Fratar, Furness ve süre fonksiyonlu tekrarlama (time function iteration) gibi büyüme modelleri veya çekim (gravity), birbirine etki (interactence), elektrostatik, çoklu regresyon ve yarışan fırsatlar (competing opportunity) gibi sentetik modeller kullanılmaktadır (Kılınçaslan vd., 2017: 243).

Türel Dağılım

Türel dağılım modelinde değerlendirme yılı için öngörülen ulaşım alt yapısı ve kentteki otomobil sahipliğini göz önüne alarak dağıtım modeli ile tahmin edilmiş olan bölgeler arası yolculukların, ne kadarının özel araçlarla, ne kadarının toplu taşıma araçları ile yapılacağını öngören bir yöntem kullanılmaktadır. Böylece gelecekte farklı türlerle yapılacak yatırımların yarışan türler arasında yolculuk kaymalarını göstermesi açısından, türlerin performans ölçülerine duyarlı bir türel dağılım modeli kullanılması, dolayısıyla bir taşıma sistemine yatırım yapılması halinde, diğer türlerden bu yeni türe kayacak yolculuk miktarlarının tahmin edilmesi amaçlanmaktadır (Türkiye Belediyeler Birliği, 2014: 24).

Türel dağılım modeli oluşturulurken servis aracı kullanılması olası (ev-iş ve ev-okul) yolculuklar ile servis kullanma olanağı bulunmayan yolculuklar için farklı yöntemler kullanılabilir. Servis araçları ile yapılan yolculuklar ayrıldıktan sonra kalan matris otomobil sahibi olan ve olmayan kişiler tarafından yapılan yolculukları belirlemek üzere ikiye ayrılır. Bunun nedeni otomobil sahibi olmayan kişilerin genellikle toplu taşıma araçlarını kullanmak zorunda olmalarına karşın, otomobilden yararlanma olanağı bulunan kişilerin özel otomobil ve toplu taşıma arasında tercih yapma durumunun oluşudur. Özel otomobilden yararlanma olanağı olan kişilerin özel ve toplu taşıma arasındaki tercihlerini belirlemek için farklı modeller de kullanılabilir (Türkiye Belediyeler Birliği, 2014: 24).

Türel dağılımda ikili sapma analizi, ayrık seçim modelleri, çoklu doğrusal regresyon, logit ve probit modelleri, hiyerarşik logit, karışık çoklu logit modelleri kullanılmaktadır.

Yolculuk Atamaları

Türel dağılım modeli sonucunda özel araç, ara toplu taşıma ve toplu taşıma araçları ile bölgeler arasında yapılan yolculuk matrisleri tahmin edilmiş olur. Ancak gerek şehirlerarası transit devlet yolunun kent içerisinde bulunması nedeni ile ortaya çıkacak trafik ve şehirlerarası yolcu taşımaları, gerekse kent içindeki yük trafiğinin de modelde temsil edilebilmesi amacıyla, çalışma sırasında toplanacak verilerin analizi sonucu belirlenecek bir yöntem ile yük ve transit trafiği için de bir matris tahmin edilmelidir. Tüm bu matrisler karayolu ve toplu taşıma şebekelerine yolculuk atama modeliyle yüklenerek bağlantılar ve toplu taşıma sistemleri üzerindeki akımlar tahmin edilmektedir. Zirve saatteki akım değerlerini belirlemek üzere yapılacak bu atamalarda, yol ya da hat seçimi kişilerin yolculuk maliyetlerini en azda tutacakları varsayımına dayanmalıdır (Türkiye Belediyeler Birliği, 2014: 24).

Yolculuk maliyeti olarak, yolculuk ücreti ve yolculuk sırasında geçen zamanın parasal değerinin toplamından oluşan “genelleştirilmiş maliyet” kullanılmaktadır. Yolculuk ücreti olarak özel araçlarda yakıt, toplu taşıma araçlarında ise bilet ücretleri alınır. Yol kesimlerinin kapasitelerine ve üzerindeki trafik hacimlerine bağlı olarak yolun tıkanma durumunu göz önüne alacak karayolu atamasında tüm matrisler otomobil birimine (passenger car unit - pcu) dönüştürülür, toplu atamalarda ise kişi bazında oluşturulacak yolculuk matrisleri kullanılır. Mevcut ve önerilen toplu taşıma koridorlarında zirve saat itibariyle olası toplu taşıma şebekesindeki istasyonlar/duraklar itibariyle yüklemeler, dolayısıyla sistem tasarım kriterleri belirlenmelidir (Türkiye Belediyeler Birliği, 2014: 25).

Yolculuk atamalarında kalibrasyon; kordon noktalarından geçen günlük/zirve saat yolcu/pcu sayısının atama modeli sonucu aynı noktalardan geçeceği hesap edilen yolcu/pcu sayısı ile karşılaştırılması ile yapılmaktadır. Kalibrasyon, en uygun sonuç elde edilene kadar tekrar edilmelidir. (Türkiye Belediyeler Birliği, 2014: 25).

Yolculuk atamalarında sapma eğrileri, hep veya hiç (en kısa yol) , kapasite kısıtlı modeller kullanılmaktadır (Kılınçaslan vd., 2017: 258-263). Bu modellerin yanı sıra stokastik trafik ataması, artımlı atama, Moore’un minimum rota algoritması, ardışık ortalamalar, en yakın tahsis, kullanıcı dengesi atama, sistem optimum ataması, stokastik kullanıcı dengesi atama, dinamik atama modelleri de kullanılmaktadır.

Hedef Yılı Projeksiyonları ve Gelecekte Beklenen Darboğazların Belirlenmesi

Kentte, varsa daha önce yapılmış çalışma ve projelerin sayısal değerleri ve projeksiyonları, etüt temel yıl verileri ile karşılaştırılır ve gerekli düzeltmeler yapılır. Nüfus, işgücü ve arazi kullanım kararlarına ilişkin olarak değerlendirme ve hedef yılı tahminleri Belediyeden temin edilmelidir. Yürürlükteki nazım ve uygulama imar planları, arazi kullanımına ilişkin diğer proje ve yatırım kararları temel alınmaktadır. Kentin gelişmesine yönelik olarak derlenen ve yorumlanan bilgilerin ışığında tüm demografik, sosyal, ekonomik ve ulaşım ile ilgili hedef yılı tahminleri, çalışmanın hedef yılı olarak belirlenen 15 ya da 20 yıl sonrası için yapılmaktadır (Türkiye Belediyeler Birliği, 2014: 25).

Hedef yılı itibarıyla kentin makro formunda, arazi kullanımında, sosyoekonomik gelişiminde ve dolayısıyla yolculuk taleplerinde oluşması beklenen gelişmelerin ulaşım modeline yansıtılması amacıyla, hedef yılı arazi kullanım kararlarına bağlı olarak belirlenen nüfus-işgücü değerleri ve yolculuk üretim katsayısı kabulü ile belirlenen hedef yılı yolculuk matrisleri modeli yüklenmektedir. Bu senaryo, hedef yılına kadar gerçekleştirilmesi planlanmış, onaylı ve finansmanı sağlanmış bulunan ulaşım ve ulaşımı ilgilendiren diğer (toplu konut, turistik tesisler, organize sanayi bölgesi vb.) projelerin uygulanacağı varsayımını da içerecek, dolayısıyla eğilim alternatifi özelliklerini taşıyacaktır. Hedef yılı yolculuk üretim katsayısının tahmininde benzer kentlerimizdeki çalışmaların bulguları ve kentte bugüne kadar gerçekleştirilen çalışmalarda ortaya çıkan değerlerin gelişimi de göz önünde bulundurulmalıdır (Türkiye Belediyeler Birliği, 2014: 26).

Projeksiyonlar, kent eğilim parametreleri çerçevesinde gerçekleştirilmektedir. Bu parametrelerden bazıları: belediyenin öngörülleri, nüfus gelişimi ve dağılımı, iş yeri oluşumu ve işyeri dağılımı, eğitim kurumları dağılımı, araç sahipliği ve motorizasyon gelişimi, kentteki yaş dağılımı, arazi kullanım kararları, kentin gelişim yönü ve hızı, nazım imar planında yer alan proje ve yatırımlar, desantralizasyon potansiyeli, onaylı ve finansmanı sağlanmış, ulaşım taleplerine etki edecek projelerdir (Türkiye Belediyeler Birliği, 2014: 26).

Projeksiyonların geliştirilmesinde, taşıt sayısı/trafik yoğunluğu ve dağılımı ile trafik altyapısı bilgilerine ait hedef yılı tahminleri önemli yer tutmaktadır. Bu doğrultuda, özel ve yük taşıtları için iç trafik, kaynak-hedef, transit trafik matris-

tabloları hazırlanmaktadır. Tahmin değerleri bu matrislerden elde edilmektedir (Türkiye Belediyeler Birliği, 2014: 26).

Hedef yılı yolculuklarının dağıtımı, türel dağılımın belirlenmesi ve ulaşım şebekesine yüklenmesi ile gelecekte ulaşım şebekesi ve ana koridorlar üzerinde oluşması beklenen yolculuk taleplerinin tahmini gerçekleştirilmekte, bir diğer deyişle eğilim alternatifini altında ortaya çıkması beklenen yolculuk talepleri tahmin edilmektedir (Türkiye Belediyeler Birliği, 2014: 26).

Mevcut ulaşım yapısındaki sorunlar ve darboğazlar; eldeki bilgiler, yetkililerle, kent halkını temsil eden sivil toplum örgütleri ve üniversiteler ile yapılan görüşmeler ve müzakereler çerçevesinde belirlenmelidir. Daha sonra nüfusa ve nüfusun sosyoekonomik özelliklerine ait eğilimler sonucu hedef yılına kadar gerçekleştirilmesi planlanmış ve finansmanı sağlanmış bulunan ulaşımı ilgilendiren (toplu konut, turistik tesis, organize sanayi bölgesi vb.) projelerin uygulanacağı varsayımı altında ortaya çıkacak kent ve ulaşım yapısının devamı halinde oluşacak sorunlar ve yetersizlikler araştırılmalıdır (Türkiye Belediyeler Birliği, 2014: 27).

Yetersizlik ve sorunların belirlenmesi için önce ulaşım ile ilgili niteliksel ve niceliksel servis ve çevre standardının belirlenmesi gerekmektedir. Yolculuk süreleri, ortalama yürüme mesafeleri, trafik sıkışıklığı, bekleme süreleri, yolcu konfor standartları, hava kirliliği, görüntü kirliliği, gürültü standartlarının da belirlenmesini takiben bu standartlarla hedef yılındaki alternatif üzerinde ortaya çıkan bulgular da değerlendirilmelidir. Kıyaslamalar sonucunda belirginleşen darboğazların çözülmesi, sorunların giderilmesi ve verimsizliklerin ortadan kaldırılması için öncelikle mevcut durum analizi yapılmakta ve daha sonra kentiçi ulaşım ile ilgili aşağıda belirtildiği gibi çeşitli alternatif çözümler araştırılmaktadır (Türkiye Belediyeler Birliği, 2014: 27).

Alternatiflerin Oluşturulması ve Modelde Test Edilmesi

Kent genelinde beklenen gelişme ve değişiklikler ulaşım modeline yansıtılarak Ulaşım Ana Planının sağlıklı ve gerçekçi bir öngörüye sahip olması sağlanmalıdır. Kent için elde edilen tüm veriler, oluşturulan ulaşım modelinde değerlendirilecek, değişik çözümleri içeren davranış oryantasyonlu senaryolar hazırlanacaktır. Bu senaryolarda; Eğilim Alternatifini, Konut Dışı Yüksek Aktivite, Optimize Edilmiş Toplu Taşıma Şebekesi, Raylı Sistem Alternatifleri vs. gibi farklı kriterler temel alınmaktadır (Türkiye Belediyeler Birliği, 2014: 27).

Kent trafiğinin düzenlenmesi konut, işyeri ve eğlenme-dinlenme alanlarının birbirine yakınlaştırılması ile sağlanabilir. Akıcı bir trafik sistemi, işyeri, ev ve günlük yaşamın diğer aktiviteleri arasındaki mesafeleri azaltmakla oluşturulabilir. Kentsel fonksiyonların, çok merkezli bir gelişme içinde, sağlıklı bir şekilde birleştirilmesi gerekir. Fonksiyonlar birleştirilmiş ya da birbirinden bağımsız olsa da, fiziksel olarak bir araya getirilmelidir. Böylece kent içi ve çevre nüfus için uygun alternatif toplu taşıma trafiği olanakları planlanıp oluşturulmalıdır (Türkiye Belediyeler Birliği, 2014: 27).

Uygun toplu taşıma türlerinin seçiminde şu kriterler dikkate alınmalıdır: farklı ulaşım türlerinde taşınan yolcu sayıları, türler arası yolcu kaymaları, işletme özellikleri (hız, dakiklik, sıklık, emniyet vb.), konfor ve sistem standartları, ortalama yolculuk süreleri, aktarma şekilleri ve sayıları, hacim/kapasite oranları, gelişmiş toplu taşıma türlerinin daha fazla geliştirilme ve modern trafik sistemine entegrasyon olanağı (Türkiye Belediyeler Birliği, 2014: 27-28).

Uzun vadede alternatif çözüm toplu taşıma sistemleri üç ana kategoride incelenmelidir: Lastik tekerlekli toplu taşıma sistemleri kapsamında; otobüs toplu taşıma sistemi, trolleybüs vb., Raylı sistemler kapsamında; metro, hafif raylı toplu taşıma sistemi, tramvay, monoray vb., Kablolü ulaşım sistemleri kapsamında; fönüküler vb. sistemler (Türkiye Belediyeler Birliği, 2014: 28).

Alternatif toplu taşıma sistemleri oluşturulurken en az maliyetli çözümlerden başlanarak, yüksek maliyetlere ulaşan ve önemli yatırımları kapsayan çözümlere kadar bir dizi alternatif çözüm üretilmektedir. Bu çözümler kent içinde farklı alanlardaki ve çeşitli düzeylerdeki yolculuk taleplerine cevap vermeli, farklı türlerden oluşan ve çok tür içeren (multi-modal) alternatif yol ağı ve ulaşım sistemlerini içermelidir (Türkiye Belediyeler Birliği, 2014: 28).

İlk aşamada alternatifler ana hatları ile belirlenerek geniş bir öneri listesi oluşturulur. Bu liste üzerinden kapasite ve teknik yapılabilirlik bazında ön değerlendirme yapılarak, tüm alternatiflerin arasından ayrıntılı teste ve değerlendirmeye tutulacak ana alternatifler seçilmektedir. Ön değerlendirme sonucunda seçilen az sayıdaki toplu taşıma yol ağı-tür planı ana alternatifi (eğilim alternatifi-mevcut ulaşım yapısının korunması hali ve diğer alternatifler) kıyaslanıp, alternatiflerin avantaj ve dezavantajları tespit edilmektedir (Türkiye Belediyeler Birliği, 2014: 28).

Önerilerin geçerliliğini test etmek için ulaşım modeli kullanılmaktadır. Tercih edilen ulaşım aracını Türel Dağılım üzerinde uygulayıp, gerçeğe uygun trafik koşulları yaratılır ve trafiği rahatlatıcı/yoğunlaştırıcı sonuçlar gösterilir. Türel Dağılım üzerindeki değişiklikler tayin edilebilir olduğundan, aynı zamanda toplu taşıma sistemindeki değişiklikler de görülebilmektedir (Türkiye Belediyeler Birliği, 2014: 28).

Benimsenecek Alternatifin Seçilmesi

Yolculuk taleplerine cevap verme açısından performansları modelde test edilen ana alternatiflerin yatırım, işletme ve bakım giderleri tahmini yapılır. Her alternatifte yer alan projelerin kavramsal düzeyde maliyetleri belirlenerek, trafiğe etkilerinin yanı sıra, ekonomik olup olmadığı da ortaya konmaktadır. Tüm bu süreçler nihai karar verme sürecini etkilemektedir. Alternatiflere ilişkin yatırım, işletme ve bakım giderleri, fayda/maliyet analizleri, iç verim oranı ve net bugünkü değer analizleri, yatırım geri dönüş oranları gibi değişkenler alternatifin seçiminde dikkate alınmalıdır (Türkiye Belediyeler Birliği, 2014: 28-30).

Son değerlendirmeye alınan her bir ana alternatifin uygulanması halinde ortaya çıkacak zaman kazançları, akaryakıt tasarrufları, kazalardaki azalmalar, hava kirliliğindeki azalmalar gibi ölçülebilen yararlarla, ölçülemeyen yararlar (planlı kentsel gelişmeye etkiler, ulaşım sisteminin genel performansındaki artışlar, gürültü, estetik değerler gibi) ortaya konmalıdır. Birçok alternatif arasından yukarıda belirtilen unsurlar bazında tüm ölçülebilen ve ölçülemeyen yararlar ve maliyetler ayrıntılı olarak belirlenip kavramsal düzeyde yapılan mali ve ekonomik analiz sonucunda alternatiflerin çok ölçütlü değerlendirmesi yapılarak en iyi performans gösteren alternatif, fikir projesi hazırlanmak üzere seçilmelidir (Türkiye Belediyeler Birliği, 2014: 30).

Seçilen Alternatifin “Ulaşım Ana Planı” Olarak Geliştirilmesi

Ulaşım Ana Planı, kentin uzun dönemdeki (20 yıllık bir perspektifte) ulaşım gelişmelerini yönlendirecek, ulaşımındaki uzun dönemli yatırımları ve politikaları kent kapsamında belirlenen uzun dönemli ulaşım sisteminin gerçekleştirilme aşamaları nazım imar planına uyumlu hale getirecek projeleri ve önlemleri kapsamalıdır. Ulaşım

Ana Planı rapor ve önerileri belirlenecek bir genel strateji iki aşamalı olarak geliştirilerek; 1-5 yıllık dönemde gerçekleştirilmesi öngörülen kısa - orta dönem projeleri ve 15-20 yıllık dönemde uygulamaya konması önerilen uzun dönem proje ve önerileri her konu için ayrı ayrı tanımlanmalıdır (Türkiye Belediyeler Birliği, 2014: 30).

1.1.2. Acil Eylem Ulaşım ve Trafik İyileştirme Plan, Etüt ve Projeleri

Acil Eylem Ulaşım ve Trafik İyileştirme Plan, Etüt ve Uygulama Projeleri, ulaşım sisteminin mevcut yapı ve özellikleri konusunda toplanan bilgiler değerlendirilerek, mevcut ulaşım sistemindeki aksaklık ve darboğazların belirlenmesi ve bu sorunların giderilmesi için kısa dönemde (1-3 yıl) uygulanabilecek ulaşım ve trafik planlaması, yönetimi, trafik mühendisliği çözümlerini kapsamaktadır (Türkiye Belediyeler Birliği, 2014: 34).

Ulaşım planlamasında, çözümler kadar sorunun teşhisi de önem arz etmektedir. Kentlerimizde yoğunlukla sorunların doğru bir şekilde teşhis edilememesinden kaynaklanan ulaşım sorunları yaşanmaktadır. Ulaşım ve trafik iyileştirme etüt ve uygulama projeleri çalışmasının, en önemli aşaması; çok geniş ve çeşitli saha çalışmalarını içeren bilgilerin toplanması, analiz edilmesi ve ulaşım planlama ve trafik mühendisliği açısından değerlendirilmesidir (Türkiye Belediyeler Birliği, 2014: 34).

Bu tür çalışmalar özellikle yeni kurulmuş veya daha önce hiç çalışma yapılmamış belediyeler için, kısa zamanda ve daha ekonomik yöntemler ile kentiçi ulaşım ile ilişkin çözümlerin ihtiyaç olduğu koşullarda çok faydalıdır. Bu çalışmaların tamamlanmasından sonra “Ulaşım Ana Planı” hazırlama süreci gerçekleştirilebilir (Türkiye Belediyeler Birliği, 2014: 34).

Acil Eylem Ulaşım ve Trafik İyileştirme Planları, genel itibariyle şebeke yapısı, ulaşım sistemleri üzerinde yapılan değişiklik ve iyileştirmeler ile trafik altyapısı için hazırlanacak teknik uyarlamaları kapsamaktadır. Sorunların aciliyet durumu dikkate alınarak, ulaşım ana şebekesi ve trafik mühendisliği kriterleri çerçevesinde, ulaşım sistemi ve trafik akımlarının iyileştirilmesi için gerekli Trafik Dolaşım Planı hazırlanır. Bu plan üzerinde darboğaz teşkil eden yetersiz kapasitedeki kavşakların ve gerekli görülen yol kesitlerinin koridor düzenlemelerini kapsayacak Mühendislik Avan Projeleri hazırlanır. Acil Eylem Ulaşım ve Trafik İyileştirme Plan, Etüt ve Uygulama Projeleri, kent içi trafiğin yeniden düzenlenmesinin yanı sıra, toplu taşıma

sisteminin fiziksel ve kurumsal yapılanmasının geliştirilme önerilerinin hazırlanmasını da kapsamaktadır (Türkiye Belediyeler Birliği, 2014: 34-35).

Çalışma kapsamında, tüm toplu taşıma güzergâhları gözden geçirilip, yolculuk talepleri dikkate alınarak bütünleşik bir toplu taşıma planı hazırlanır. Bu planda; toplu taşıma araçları için güzergâhlar ve durak yerlerinin belirlenmesi, verimlilik ve etkinliğinin artırılması ve toplu taşıma sistemi kurumsal yapılanması için araştırma yapılarak karşılaştırmalı öneriler hazırlanır (Türkiye Belediyeler Birliği, 2014: 35).

Acil Eylem Ulaşım ve Trafik İyileştirme Planlama süreci çeşitli kamu ve özel sektör kuruluşlarından mevcut verilerin toplanması, anket ve sayımlarla yeni verilerin toplanması, verilerin analizi ile mevcut sorun ve yetersizliklerin değerlendirilmesi, ulaşım ve trafik iyileştirme programının hazırlanması aşamalarında gerçekleştirilir (Türkiye Belediyeler Birliği, 2014: 37-39).

1.1.3. Raylı Sistem Hatları Ön/Kesin Projeleri ve Fizibilite Etütleri

Ulaşım ana planı hazırlandıktan sonra plan kapsamında fizibilite çalışmaları sonucu uygun olduğu öngörülen raylı sistem yatırımlarından öncelikli olandan başlamak üzere yapımına karar verilen hattın ön/kesin projeleri ve Proje Raporu Ulaştırma, Denizcilik ve Haberleşme Bakanlığı Altyapı Yatırımları Genel Müdürlüğü esaslarına uygun olarak hazırlanır (Türkiye Belediyeler Birliği, 2014: 41).

Ulaşım ana planı kapsamında önerilen raylı sistem şebekesi öncelikli hattına ilişkin ön/kesin projeler şu konuları kapsar: Jeolojik /Jeoteknik Etüt, Topografik Etütler, Haritalama ve Tesisler, Güzergah Belirlenmesi ve İstasyonlar, Tıp Kesitler, Enerji Kaynağı ve Elektrifikasyon, Sinyalizasyon ve Haberleşme, Ücret Toplama Sistemi, Araçlar, Kontrol Merkezi, Depo Tesisleri ve Atölye Binası (Türkiye Belediyeler Birliği, 2014: 41).

Projenin ekonomik ve mali uygunluğunun değerlendirilmesi için ulaşım modeli de dahil olmak üzere çeşitli verilerden yararlanılır. Önerilen raylı sistemin hizmet edeceği yolculuk tahminleri, Ulaşım Ana Planı çalışmaları sırasında kullanılan ulaşım modeli sonuçlarından elde edilir. Yatırım giderleri, keşifler, işletme, bakım ve onarım giderleri ise mühendislik etüt ve proje çalışmaları sonucunda hesaplanır. Son yıllarda kentlerimizde ve diğer ülke kentlerinde uygulanmış, ya da uygulanmakta olan raylı sistem projelerindeki finansman kaynaklarının temin koşulları dikkate alınarak, belirlenen finansman senaryolarına dayandırılan gelir ve gider analizleri yapılır,

projenin mali ve ekonomik performansı değerlendirilir. Bir yatırım projesi veya fizibilitesi için sistemin işletmeye geçtikten sonra sürdürülebilirliğinin sağlanması önemlidir. Proje tamamlandıktan sonra proje hedeflerinin kendi yarattığı fonlarla varlığını sürdürmesi gerekmektedir (Türkiye Belediyeler Birliği, 2014: 43).

Raylı Sistem Hattı Fizibilite Etüdünün başlıkları şu şekilde olmalıdır: projenin tanımı ve kapsamı, projenin teknik özellikleri, proje giderleri, proje gelirleri, projenin mali ve ekonomik değerlendirmesi. Projenin teknik ve işletme özellikleri başlığı altında: hattın güzergahı, yaklaşık uzunluğu, durak/istasyon sayısı, tipleri, yerleri, depo ve atölye sahaları, bir yöndeki saatlik yolcu taşıma kapasitesi, hattın teorik işletme hızı, araçların dolaşım süresi, hafta içi, hafta sonu ve tatil günlerinde uygulanacak sefer saatleri, hat üst yapıları, trafolar, elektrik tesisatları, sinyalizasyon, ücret toplama sistemi gibi teknik donanımlar vb. yer alır. Proje giderleri başlığında projenin yapımı için gereken yatırım giderleri, işletme giderleri, bakım ve onarım giderleri, amortisman giderleri, finansman giderleri yer alır. Proje gelirleri başlığında yolcu gelirleri, kira gelirleri, reklam gelirleri yer alır. Projenin mali ve ekonomik değerlendirmesi başlığında yatırım geri ödeme süreleri, nakit akışları, mali indirgenmiş fayda/maliyet, mali iç verim oranları, mali net bu günkü değer analizleri gibi mali analiz sonuçları ve projenin ölçülebilen (kazaların azalması, yolculuk süresinin azalması, akaryakıt tüketiminin azalması, otobüs işletme giderlerinin azalması vb.) ve ölçülemeyen faydaları (hava kirliliği ve gürültüdeki azalmalar vb.) yer alır (Türkiye Belediyeler Birliği, 2014: 44-49).

1.2. TOPLU TAŞIMA PLANLAMASINDA AKILLI KART VERİLERİNİN KULLANIMI

Akıllı kart verileri uzun vadeli planlama çalışmalarında, yolculuk talep tahminlerinde ve yolcu davranışlarının analizinde stratejik düzeyde kullanılabilir. Taktiksel düzeyde sefer çizelgelerinin düzenlenmesi, yolcuların iniş noktalarının belirlenmesine yönelik çalışmalarda da akıllı kart verileri kullanılabilir. Operasyonel düzeyde ise mevcut durum analizi, yolcuların rota seçimlerini etkileyen faktörlerin belirlenmesi için akıllı kart verileri kullanılabilir.

1.2.1. Akıllı Kart Verileri ile Toplu Taşıma Performansının Ölçümü

Morency, Trépanier ve Agard 2007 yılında Dünya Ulaştırma Araştırmaları Konferansı'nda sundukları bildiride transit ağ performans ölçütlerini tahmin etmek için akıllı kart verilerinin kullanımını göstermişlerdir. Yazarlar akıllı kart verilerinden belirli bir mekan veya zaman seviyesinde şebeke arzının performansı ve yolcu hizmetine ilişkin istatistiklerin hesaplanabileceğini göstermişlerdir (Morency vd., 2007).

Trépanier ve arkadaşları 2009'da yayınladıkları makalede, toplu taşıma sisteminin performansını değerlendirmek için akıllı kart verileri kullanımını göstermişlerdir (Trépanier vd., 2009).

El-Geneidy ve arkadaşları 2011'deki çalışmalarında akıllı kart verilerini metro transit sisteminde şehirler arası bir rota boyunca performans sorunlarını değerlendirmek için kullanmışlardır. Çalışma zamanları, yolculuk süreleri, tarifelere uyma düzeyini ölçmek üzere zaman noktası bölümü ve rota düzeyi adında iki kriter belirlemişlerdir. Bu çalışmada yazarlar, ana hatları değiştirmeden bazı tarife değişikliklerine ihtiyaç olduğunu gözlemişlerdir. Ayrıca, yazarlar analizlerde rota boyunca bazı durakların yeterince kullanılmadığını belirlemişler ve durak sayısını azaltarak hizmet değişkenliğini azaltmak amacıyla durak konsolidasyonunu önermişlerdir (El-Geneidy vd., 2011).

Transit Cooperative Research Programı'nın 2006 yılında yayınladığı makalelerinde akıllı kart verileri ve otomatik araç konum verileri (GPS) kullanılarak çeşitli analizler uygulanmıştır. Çalışmada, akıllı kart verileriyle, toplu ulaşım sisteminin sefer süreleri, planlanan sürelere uyum düzeyi, yolcuların bekleme süreleri, talep düzeyi, sefer aralıklarının düzenliliği, seferlerdeki yolcu yoğunlukları, işletme hızı ve gecikmelere yönelik birçok analiz yer almaktadır (Özuysal vd., 2015).

Eom ve arkadaşları 2015'de yayınlanan makalelerinde Seul'deki bir toplu taşıma şirketine ait otomatik ücret toplama verilerinden zaman çizelgesine uyma, doluluk oranı, otobüslerin işletme hızı gibi hizmet ölçütleri ile toplu taşıma performansını analiz etmişlerdir (Eom vd., 2015).

1.2.2. Akıllı Kart Verilerinden Başlangıç-Varış (Origin-Destination - OD Matris) Matrislerinin Tahmini

Lee ve arkadaşları 2011’de Dünya Demiryolu Araştırmaları Kongresi’nde sundukları bildiride, akıllı kart verilerinden başlangıç-varış matrislerini hesapladıklarını, talep analizi yaptıklarını, hizmet performans değerlendirmesi, çok modlu transit atama ve optimizasyon yaptıklarını duyurmuşlardır (Lee vd., 2011).

Delice 2012 tarihli doktora tezinde, akıllı kart verilerini kullanarak başlangıç-varış matrislerini hesaplamak için bir algoritma geliştirmiştir. Normalde başlangıç-varış matrisleri anket yöntemiyle toplanan verilere göre hesaplanmaktadır (Delice, 2012).

Ma 2013’deki doktora tezinde yolcuların seyahat kalıplarını zamansal ve mekânsal özelliklerine göre Markov zincirine dayalı Bayes karar ağacı ile modellemiştir. Bu seyahat kalıpları yardımıyla bireysel seviyede hedef duraklar aktarma analizi yardımıyla çok günlük veriden tahmin edilebilmektedir (Ma, 2013).

Van Oort, Brands ve de Romph 2015’de sundukları bildirilerinde akıllı kart verilerinden başlangıç-varış matrislerini hesapladıklarını ve bu matris yardımıyla talep analizi yaptıklarını raporlamışlardır (van Oort vd., 2015).

Kohani, 2015 yılında yapılan Yöneylem Araştırması Konferansında sunduğu bildiride Zilina Belediyesi akıllı kart verilerine bir yolcu zincirleme yöntemi uygulamıştır. Bu yöntemle elde ettiği başlangıç-varış matrislerini kullanarak Zilina Belediye bölgesinin tarife segmentlerine ayrılması için bir tamsayı programlama modeli kurmuştur. Analizin sonucunda yeni tarife bölgeleri eklenmiş ve yerel yöneticilerle sonuçlar tartışılmıştır. Yazar neticede tasarımların sağlamlığının bulanık yaklaşımla test edilmesi gerektiğini belirtmiştir (Kohani, 2015).

1.2.3. Akıllı Kart Verilerine Veri Madenciliği Süreçlerinin Uygulanması

Agard ve arkadaşlarının 2006’da sundukları bildiride, yazarların akıllı kart verilerine hiyerarşik kümeleme uygulayarak kart kullanıcılarını 4 gruba ayırdıkları görülmektedir. İlk grup hem sabah hem de öğleden sonraki yoğun saatlerde seyahat eden düzenli kart kullanıcılarıdır. İkinci grup için bir seyahat modeli gözlenmemiştir. Üçüncü grup günün ilk yarısında yoğun talep oluştururken, son grup ulaşım ağını en az kullanan gruptur (Agard vd., 2006).

Khanadar ve arkadaşları 2016 yılında akıllı kart verilerinde kümeleme ile veri madenciliği uygulamışlardır. Yazarlar öncelikle Density Based Spatial Clustering of Applications with Noise (DBSCAN) algoritması ile öğrencilerin seyahat modellerini ortaya çıkarmıştır. Ardından öğrencilerin özdeş seyahat modellerinin belirlenmesi, mekansal ve zamansal özelliklerine göre öğrencilerin farklı gruplara ayrılması sağlanmıştır. Düzenlilik kümelemesi için “DBSCAN” ve “K-ortalamlar ++” algoritmaları kullanılmıştır (Khanadar vd., 2016).

Nagareshmi ve Palagan 2016’daki çalışmalarında metro yolcularının akıllı kart verilerinden zamansal ve mekansal segmentasyon için faydalanmışlardır. Yazarlar, yolculukları önce transfersiz, tek transferli ve çok transferli şeklinde 3 sınıfa ayırmışlar, daha sonra zamansal ve mekansal segmentasyon yapmışlardır. Zamansal segmentasyonda, çoğu gün 08:00-10:59 ile 18:00-20:59 periyotlarındaki seyahatlerin düzenli olduğu ve 08:00-10:59 periyodundaki yolculuklarda, başlangıç zamanı ve sürenin varyasyona sahip olduğu yazarlar tarafından bildirilmektedir. Yazarlar, akıllı kart verilerinden başlangıç-varış matrisini hesaplamışlardır. Bazı başlangıç-varış çiftlerinde bazı yolculukların süresinin aynı çiftteki başka yolculuklardan çok fazla olduğu yazarlar tarafından gözlemlenmiştir (Nagareshmi ve Palagan, 2016).

El Mahrsi ve arkadaşları 2017’deki makalesinde eğimli sezgisel kümeleme ile kart kullanım yoğunluklarına göre 13 yolcu kümesi keşfettiklerini raporlamıştır. Örneğin, küme 3’te yoğunluk akşam saatlerinde iken küme 4’de sabah akşama kadar devam eder. Küme 1 haricinde, diğer üç küme büyük ölçüde serbest seyahat yolcularından oluşur. 5. ve 6. kümelerde sabah ve akşam işe gidiş ve dönüş saatlerinde yoğun kullanım görülmektedir. 7, 8, 9 ve 10 nolu kümelerdeki yolcular Çarşamba günleri kayan bir ikinci zirve davranışı gösterirler. 11 ve 12. kümeler sabah, öğle ve akşam saatlerinde pik yapmaktadırlar. Yazarlar, 13. kümedeki yolcuların talebinin sabah erken saatlerde (06:00) tek bir pik oluşturduğunu, akşam saatlerinde ise yoğunluğun pik oluşturmada yayılım gösterdiğini raporlamışlardır (El Mahrsi vd., 2017).

Faroqi ve arkadaşları 2017’de yayınlanan makalelerinde akıllı kart verilerinden kart sahiplerini zamansal-mekansal ayrıma tabi tutabilmek amacıyla mekansal benzerlik ve zamansal benzerlik ölçütleri geliştirmişlerdir. Yazarlar bu ölçütleri kullanarak toplu taşıma kullanıcılarının mekansal benzerlikleri ile zamansal benzerlikleri arasındaki ilişkileri incelemişlerdir. Mekansal benzerlik ölçüsü, yolcuların yolculuk mesafeleri ve hareket yönünü hesaba katmaktadır. Zamansal

benzerlik ölçüsü sürekli doğrusal bir uzayda hem biniş hem de iniş zamanlarını dikkate alır. Yazarlar ayrıca, yolculuk süresi ve uzunluğu ile mekansal ve zamansal benzerlik değerleri arasındaki ilişkileri incelemişlerdir (Faroqi vd., 2017).

1.2.4. Akıllı Kart Verileriyle Toplu Taşıma Rota Planlaması

Nasibov ve arkadaşları 2013'deki makalelerinde rotada ölü seyahat veya ölü mesafe olarak bilinen yolcusuz seyahat edilen mesafeyi azaltarak toplam yakıt tüketimi minimize etmeye çalışmışlardır. Yazarlar, toplam ölü yolculuk mesafesini minimize eden dört matematiksel model kurmuş ve sonuçlarını göstermişlerdir. Yazarlar bu modellerin uygulanması sonucunda önemli iyileştirmeler sağlandığını göstermiştir (Nasibov vd., 2013).

Eliyi ve Eliyi 2014 yılında 7. Uluslar arası Ulaşım Teknolojileri Sempozyumunda yayınladıkları bildiride hat-bazlı iniş durağı tahmin modeli geliştirmişler, bu model ile engelli kart kullanıcıları için başlangıç-varış matrislerini hesaplamışlardır. Hesaplanan başlangıç-varış matrislerinden yeni hatların planlanması ve bu hatlara ilişkin çizelgelerin oluşturulması için yöntemler geliştirmişlerdir (Eliyi ve Eliyi, 2014).

Nasibov ve arkadaşları 2016'daki çalışmalarında durakların bulanık tercih derecelerine dayalı çok ölçütlü bir rota planlama yaklaşımı önermişlerdir. Bir başlangıç ile son durak arasındaki optimum rotalar, genellikle en yüksek tercih derecesine sahip alternatifler arasından seçilen uygun transfer noktaları kullanılarak oluşturulur. Model aynı rotayı oluştururken başlangıç ve son arasında en az sayıda durak olmasını hedeflemektedir. Bulanık optimal çözümler yazarlar tarafından geliştirilen bir sezgisel algoritma tarafından oluşturulmaktadır (Nasibov vd., 2016).

1.2.5. Akıllı Kart Verileriyle Optimum Sefer Sıklığı Planlaması

Utsunomiya ve arkadaşlarının 2006'daki çalışmalarında, akıllı kart kullanıcılarının kullanım geçmişleri incelenerek biniş sıklıkları hesaplanmıştır (Utsunomia vd., 2006). Bu inceleme sonuçlarına göre, hatların sefer sıklıklarında çeşitli düzenlemeler yapılabileceğini göstermişlerdir.

Selçuk Alp'in 2008'de yazdığı doktora tezinde, Mayıs-Haziran 2006 döneminde İstanbul Elektrik Tramvay ve Tünel İşletmeleri (İETT)'ne bağlı Kağıthane

garajındaki 41 otobüs hattına ait verileri kullanarak her hatta optimum sefer sıklığını hesaplamak için farklı sistem ve hedef kısıtlarına, farklı amaç denklemlere sahip 6 doğrusal hedef programlama modeli geliştirerek bu modelleri winqsb yazılımı ile çözmüştür (Alp, 2008: 148-160).

Nurcan Uludağ 2010 tarihli doktora tezinde, İzmir ilinde Lozan ve Montrö duraklarından geçen toplam 26 otobüs hattına ait, sabah 08:00-11:00 saatleri arasındaki sefer sayılarını optimize etmek amacıyla bir doğrusal hedef programlama modeli kurmuş ve Winqsb yazılımı ile çözmüştür. Modelin çözümü ile elde edilen yeni sefer çizelgesinde sefer sayısında yaklaşık % 25,8'lik bir azalma sağlanmıştır (Uludağ, 2010: 57-62).

Alper Deri, 2012 tarihli yüksek lisans tez çalışmasında İzmir güney-batı bölgesi ile Konak-Halkapınar arasında hizmet veren 11 adet otobüs hattının, sabah zirve saati (07:00-09:00) içerisinde kent merkezine gidiş yönündeki talebe cevap verecek uygun otobüs sefer sıklıklarını Doğrusal Hedef Programlama (DHP) yöntemi ve ampirik bağıntılar ile belirlemiştir. Yazar doğrusal hedef programlama modeli ile hesaplanan optimum sefer sayısının mevcut durumdan daha düşük olduğunu ve ampirik bağıntıyla toplamda aynı sefer sayısının belirlendiğini raporlamıştır. Buna karşın atıl kapasite miktarı bakımından doğrusal hedef programlama modelinin daha iyi sonuç verdiğini göstermiştir (Deri, 2012: 121-124).

1.2.6. Akıllı Kart Verilerinden Yolcu Davranışlarının Analizi

Agard ve arkadaşları, akıllı kart kullanıcılarının izledikleri rotaların takip edilerek davranışlarının daha iyi anlaşılabilceğini belirtmişlerdir. Yazarlar akıllı kartlardaki biniş tarihi, saati ve yeri verilerini kullanarak tipik kullanıcıları belirlemişler ve günlük, haftalık, aylık veya mevsimlik kart kullanım değişikliklerini analiz etmişlerdir (Agard vd., 2006).

Morency ve arkadaşları 2006'da Akıllı Ulaşım Sistemleri Dokuzuncu Uluslararası IEEE Konferansı'nda sundukları bildiride akıllı kartlara ait verilerdeki biniş tarihi, saati ve yeri verilerini kullanarak durak kullanım sıklıklarını ve yoğunluklarını belirlemişlerdir (Morency vd., 2006).

Özuysal ve arkadaşları 2016 yılındaki makalelerinde İzmir toplu taşıma sistemi akıllı kart verileri ve saha gözlemlerinden yararlanarak hatların güvenilirliği üzerinde etkili olan yolcu iniş-biniş sürelerini modellemişlerdir (Özuysal vd., 2016).

Köse ve Özdemir 2017’de 8. Uluslar arası Gelişmiş Teknolojiler Sempozyumunda sundukları bildirilerinde Balıkesir toplu taşıma sisteminin akıllı kart verilerinden yolcuların davranışlarını analiz etmişlerdir. Çalışmayı yürüten yazarlar Balıkesir ilinde toplu taşıma sisteminin yeterince kullanılmadığını, sık yolculuk yapanların az olduğunu, eğlence amaçlı yolculukların daha yoğun olduğunu belirlemişlerdir. Tam kart ve indirimli kart sahiplerinin talep düzeylerinin hafta içi sabah saatlerinde (07:00-09:00) ve akşam mesai bitimlerinde (16:00-18:00), hafta sonu ise gün ortasından akşam saatlerine kadar (12:00-20:00) pik yaptığını tespit eden yazarlar, aynı zamanda 60 yaş ve üstündeki kullanıcıların taleplerinin hem hafta içinde (10:00-18:00) hem de hafta sonunda (11:00-18:00) gün ortasında pik yaptığını gözlemişlerdir (Köse ve Özdemir, 2017).


1.2.7. Akıllı Kart Verilerinden İniş Duraklarının Tahmini

Akıllı kart verileri ile her sefere ait yolcu-yük profilleri çıkarılarak hatlara ait maksimum yükleme noktaları ve yük değerleri bulunmakta, bulunan bu değerlere göre servis sıklıkları revize edilebilmektedir. Birçok toplu ulaşım sisteminde inen yolcuların sayımını yapan bir teknoloji bulunmadığından, inen yolcuların tespiti için çeşitli algoritmalar ve hesaplama yöntemleri geliştirilmiştir (Trépanier vd., 2007).

Başlangıç-varış (BV) veya Origin-Destination (OD) matrisleri bireysel yolculuk takibi verileri yardımıyla hesaplanabilir. Buradaki sorun akıllı kart verilerinde kişilerin otobüslere binış kaydı olup iniş kaydı olmamasıdır. Bu nedenle bireylerin indikleri duraklar bazı varsayımlarla tahmin edilmeye çalışılır. Trépanier ve arkadaşlarının (2007)’deki çalışmalarında bu varsayımları şu şekilde göstermişlerdir:

- Sabah ilk binış bireyin ikametne yakındır ve akşam iniş durağı büyük ihtimalle bu durağa yakın bir durak veya aynı durak olacaktır.
- Akşam son dönüş seferinin iniş durağı bir sonraki günün ilk durağına yakın bir durak veya aynı durak olacaktır.
- Aktarmalı yolculuklarda ikinci binışe çok yakın bir noktada iniş yapıldığı için iniş noktalarının bulunması daha kolay olmaktadır. İniş noktalarının tahmin edilmesindeki kritik faktörlerden biri de yürüme mesafesidir. İniş ve binış noktalarının arasındaki mesafe yürüyüş mesafesini aşmamalıdır. Bu tahmin yöntemi Şekil 2’de gösterilmiştir.

Şekil 2: Akıllı Kart Kullanıcılarının Biniş Durağından İniş Durağının Tahminlenme Süreci



Kaynak: Trépanier vd., 2007.

Şekil 2’de i kullanıcısının tahmin edilen olası iniş durakları kare ile gösterilen duraklardır. Görüldüğü gibi tahmini iniş durakları, aktarma yaparak gerçekleştirdiği yeni yolculukların biniş noktalarına oldukça yakındır. S_{1ik}^B noktasından binen i yolcusu ikinci rotadaki S_{2ik}^B durağından biniş yapmıştır. İlk rotada bu durağa en yakın durak kare ile gösterilen d_{1ik} durağıdır. İkinci rota tahmini iniş durağı sonraki rotasındaki biniş durağı olan S_{3ik}^B durağına en yakın durak olan d_{2ik} durağıdır.

Diker, 2015 yılındaki çalışmasında yukarıda anlatılan yöntemi yolculuk zincirleme yöntemi olarak adlandırmıştır. Bu çalışmada koordinatlardan mesafenin hesaplanması için Sinnott (1984) tarafından önerilen Haversine formülünün kullanılması önerilmiştir. Diker çalışmasında yolculuk zincirleme ile belirlenemeyen iniş durakları için rasgele atama tahmin yöntemini (Random Assignment Estimation Method – RAEM) önermiştir (Diker, 2015).

Yolculuk zincirleme yaklaşımı ile belirlenemeyen iniş durakları, biniş ve iniş sayılarını dengeleyecek şekilde tahminlenmeye çalışılır. Bu yöntem, yolcuların birbirine benzer akış modelleri izleyebileceği fikriyle geliştirilmiştir.

Bu yöntemde d gününün q .bölümü içindeki l hattında S_l^k ’den S_l^m ’ye seyahat eden toplam yolcu sayısı $MC_{dq}(l, S_l^k, S_l^m)$ olarak adlandırılır ve aşağıdaki şekilde hesaplanır:

$$MC_{dq}(l, s_l^k, s_l^m) = \sum_c^{cd} OD_{dq}(l, c, s_l^k, s_l^m) \quad \text{Denklem 1}$$

Tüm günlerin q.bölümü içindeki l hattında S_l^k 'den S_l^m 'ye seyahat eden ortalama yolcu sayısı:

$$\overline{MC_q}(l, s_l^k, s_l^m) = \frac{\sum_{d=1}^D MC_{dq}(l, s_l^k, s_l^m)}{D} \quad \text{Denklem 2}$$

şeklinde hesaplanır. Günün herhangi bir bölümü için denklem 2'de verilen ortalama değerin olasılığı aşağıdaki gibi hesaplanır:

$$P_q(l, s_l^k, s_l^m) = \frac{\overline{MC_q}(l, s_l^k, s_l^m)}{\sum_{j=k+1}^{|S1(l)|} \overline{MC_q}(l, s_l^k, s_l^j)} \quad \text{Denklem 3}$$

Rastgele sayı $u \in (0,1]$ rasgele sayı üretici tarafından iniş duraklarını tahminlemek için üretilir. Koşulu sağlayan iniş durağı $s^* = s_l^{r+1}$, aşağıdaki denklemle tahmin edilir:

$$\sum_{m=k}^r P_q(l, s_l^k, s_l^m) < u \leq \sum_{m=k+1}^{r+1} P_q(l, s_l^k, s_l^m), r = k, \dots, |S1(l)| - 1 \quad \text{Denklem 4}$$

Denklem 4'deki koşula uygun olarak bir s^* atandığında günün o bölümünde S_l^k 'den S_l^m 'ye seyahat eden yolcuların 15 günlük dağılımını bozmayan bir tahmin yapılmış olur.

Diker çalışmasında yolculuk zincirleme ve RAEM yaklaşımları kullanılmasına rağmen hala bazı iniş duraklarının tahmin edilemediğini görmüştür. Bu durum, daha önce elde edilen kalıpları kullanarak herhangi bir hatta belirli biniş durağı için herhangi bir iniş durağı tahmini olmadığında ortaya çıkar. Bu nedenle, iniş durağı biniş hattının son durağı olarak tahmin edilir ve bu yöntemle Son Durağa Atama Yöntemi (Assignment to Last Stop Method - ALSM) denir (Diker, 2015: 10).

Alsger ve arkadaşları 2016'da yayınlanan eserlerinde yolculuk zincirleme yaklaşımında inerken de kart basılan akıllı kart sistemlerinde bir sorunla karşılaşabileceğini göstermiştir. Bu sistemde kullanıcı inerken kart basmayı unutsa en son durak iniş durağı olarak belirlenmektedir. Bu durumda ikinci biniş durağından mesafenin fazla olması nedeniyle birinci iniş durağının belirlenmesi mümkün olmayacaktır. Kullanıcı kartı basmış olsaydı birinci iniş durağını tespit etmek mümkün

olacaktı. Yazarlar bu tür hatalı akıllı kart hareketlerinden kaynaklanan problemi gidermek için algoritmayı değiştirmişlerdir (Alsger vd., 2016).

1.2.8. Jeodezik Mesafe Ölçüleri


Jeodezik mesafe ölçümleri için rotalama problemlerinde, tesis kuruluş yeri seçimlerinde bazı çalışmaların kısa mesafe ölçütleri olan Öklid, Manhattan veya Chebyshev mesafelerini kullandıkları görülmüştür. Bu ölçülerden en fazla öklid mesafesinin tercih edildiği görülmektedir. Benzer problemler için çok sayıda çalışmada ise dünyanın yapısı nedeniyle küresel veya eliptik mesafe yaklaşımlarının kullanıldığı görülmektedir. Eliptik yaklaşım olan Vincenty mesafesi daha doğru sonuçlar vermesine karşın hesaplama kolaylığı ve hızı nedeniyle küresel yaklaşım olan Haversine formülünün daha yaygın kullanıldığı görülmüştür.

1.2.8.1. Kısa Mesafe Ölçüleri

Öklid Mesafesi

Zarinbal 2009'daki çalışmasında lokasyon problemlerinin % 63'ünde öklid ve manhattan mesafeleri kullanıldığını tespit etmiştir. Şekil 2'de gösterilen Öklid mesafesi, bir noktadan diğerine doğrudan kuş uçuşu gidilebileceğini varsaymaktadır (Montreuil, 2008; Melachrinoudis ve Xanthopoulos, 2003).

Şekil 3: Öklid Mesafesi




A (x_1, y_1) ve B (x_2, y_2) koordinatlarına sahip iki nokta A ve B arasındaki öklid uzaklığı matematiksel olarak;

$d = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} = \sqrt{4^2 + 2^2} = \sqrt{20} = 4,473136$ şeklinde gösterilir.

Manhattan Mesafesi

Manhattan mesafeleri seyahatin Şekil 3'deki gibi sadece kuzey-güney ve doğu-batı arterleri gibi iki dik yönde yapılabildiği durumlarda uygulanabilir.

Şekil 4: Manhattan Mesafesi



Manhattan mesafesi matematiksel olarak;

$d = |x_1 - x_2| + |y_1 - y_2| = |2 - 4| + |4 - 8| = 2 + 4 = 6$ şeklinde ifade edilir.

Chebyshev Mesafesi

İki nokta arasındaki mesafe, bu iki nokta arasındaki en uzak boyuttaki uzaklıktır. Yani, Şekil 3'deki dik uzunluklardan uzun olanı (4) Chebyshev mesafesidir. Satranç tahtası uzaklığı olarak da isimlendirilir.

Chebyshev mesafesi matematiksel olarak;

$d = \text{Maksimum} \{|x_1 - x_2|, |y_1 - y_2|\} = \text{Maksimum}\{2, 4\} = 4$ şeklinde gösterilebilir.

1.2.8.2. Uzun Mesafede Kullanılan Ölçüler

Uzun mesafeler için dünyanın küresel veya eliptik yapısına uygun mesafe ölçüleri geliştirilmiştir. Bunlar; Haversine mesafesi ve Vincenty mesafesidir. Haversine formülü dünyanın şeklini küresel olarak değerlendirirken, Vincenty formülü eliptik olarak değerlendirmektedir. Bu nedenle Vincenty mesafesi daha doğru sonuç vermektedir.

Haversine Mesafesi

Dünyanın küresel şeklinden dolayı harita üzerindeki iki nokta arasındaki mesafe, koordinatları bilinen iki noktanın doğrusal mesafesi biçiminde çözüldüğünde yeterince doğru sonuçlar vermeyebilir. Bu nedenle küresel geometriye dayanan Haversine formülü kullanılır. Haversine formülü kısa mesafeler için bile yeterli sonuçlar vermektedir (Altınışık, 2013: 3).

Küresel trigonometride mesafelerin ölçülmesi, kenarları büyük daireler şeklinde olan küresel üçgenlerin çözülmesine dayanır (Das vd., 2001). Şekil 4'de olduğu gibi, büyük daire halkaları küresel üçgenin kenarlarını oluşturur ve iki yayın kesiştiği yerde küresel bir açı oluşur. Başka bir deyişle, yay uzunlukları, kürenin merkezindeki açının bir ölçüsüdür ve yaylar arasındaki küresel açılar yayları oluşturan düzlemlerin kesişme açısının bir ölçüsüdür. Dünyada, ekvator ve boylamlar doğal büyük çemberlerdir. Aynı şekilde, dünya çevresinde onu iki eşit yarıküreye ayıran herhangi bir dairesel yol bir büyük çemberdir. Küresel trigonometri, yay uzunlukları (kenarlar) ve yaylar arasındaki küresel açılar arasındaki ilişkileri kapsar (Mwemezi ve Huang, 2011: 23).


Çalışmalar dünya yüzeyindeki herhangi iki konum arasındaki en kısa mesafenin, bu iki konumu birleştiren büyük dairenin yay boyunca uzandığını göstermiştir. Bu nedenle, küresel bir yüzeyde, çoğunlukla jeodezik olarak adlandırılan büyük bir daire yolu her zaman iki nokta arasındaki en kısa yoldur (Ross, 2002). Bu nedenle, bir küre üzerinde doğrudan birbirinin tam karşısında olmayan iki noktası arasında benzersiz bir büyük daire bulunur (Mwemezi ve Huang, 2011: 23).

Küresel geometri ile Öklid geometrisi arasındaki temel farka gelince, mesafe için eşitliklerin bu iki bilgi alanında farklı biçimler alacağı açıktır. Temel olarak, Öklid uzayındaki iki nokta arasındaki mesafe, bir noktadan diğerine doğru olan düz bir

çizginin uzunluğudur; küresel geometride düz çizgiler, jeodezik veya büyük daire yollarıyla değiştirilir. Coğrafi yerlerin konumları mevcut haritalar, veya GPS ve Glonass gibi küresel konumlandırma sistemlerine dayalı olarak kolaylıkla belirlenebilirken, büyük daire mesafesinin ve böylece yerler arasındaki en kısa mesafenin hesaplanması bir formül gerektirir. Boylam ve enlemleri içeren bir koordinat sistemi kullanarak, büyük bir daire boyunca mesafe üç büyük dairenin kesişimi (Frost, 1988) ile oluşturulan küresel üçgenin niceliklerini çözerek belirlenebilir:

- İki noktayı birleştiren büyük daire yayı (Şekil 4'deki c yayı)
1. Konum boyunca meridyen (Şekil 4'de C ve A'yı birleştiren meridyen)
2. konum boyunca meridyen (Şekil 4'de C ve B'yi birleştiren meridyen)

Şekil 5: Küresel Üçgen



Kaynak: Mwemezi ve Huang, 2011: 23.

Bu küresel üçgenler ve coğrafi noktalar arasındaki en kısa mesafe Haversine formülünü kullanarak denklem 5 ve 6'da gösterildiği gibi çözülür.

$$\text{Haversine}(\text{mesafe}/R) = \text{haversine}(f_{\text{boylam}}) \cos(\text{boylam } A) \cos(\text{boylam } B) + \text{haversine}(f_{\text{enlem}}) \quad \text{Denklem 5}$$

veya

$$\text{Haversine}(AB/R) = \text{Haversine}(C) \sin(a) \sin(b) + \text{haversine}(a-b) \quad \text{Denklem 6}$$

Haversine(mesafe/R): A ve B konumları arasındaki mesafenin haversine'i

f_{boylam} : sırasıyla A ve B konumlarının boylamları arasındaki farkın haversine'i

$\cos(\text{boylam } A)$: A konumu boylamının kosinüsü

$\cos(\text{boylam } B)$: B konumu boylamının kosinüsü

haversine (fenlem): A ve B konumlarının enlemleri arasındaki farkın haversine'i

R: Dünyanın yarıçapı

Haversine fonksiyonu:

Haversine (x) = $\sin^2 \frac{x}{2}$ yerine yazılırsa denklem 1 aşağıdaki şekli alır:

$$\sin^2 \frac{\text{mesafe}}{2R} = \sin^2 \frac{\text{fboylam}}{2} \times \cos(\text{boylam } A) \times \cos(\text{boylam } B) + \sin^2 \frac{\text{fenlem}}{2}$$

Mesafe çekilirse:

$$\text{Mesafe} = 2 \times R \times \arcsin \sqrt{\sin^2 \frac{\text{fboylam}}{2} \times \cos(\text{boylam } A) \times \cos(\text{boylam } B) + \sin^2 \frac{\text{fenlem}}{2}} \quad \text{Denklem 7}$$

Denklem 7'deki haversine formülü kullanılarak dünya üzerindeki iki konumun koordinatlarından bu iki konum arasındaki mesafe doğru olarak hesaplanabilir. Bu formülde koordinat bilgilerinin öncelikle radyana çevrilmesi gerekmektedir.

Vincenty Mesafesi

İki nokta arasındaki mesafe hesabında daha yüksek hassasiyet elde etmek için Vincenty'nin formülü kullanılabilir. Bu formül jeodezide kullanılır ve bir kürenin yüzeyindeki iki nokta arasındaki mesafeyi hesaplamak için iki iteratif yöntemle dayanmaktadır. Bu yöntemler dünyanın şeklinin bir eğik küre olduğu varsayımına dayanır ve bu nedenle, küresel bir dünya varsayımına dayanan büyük daire uzaklığı gibi yöntemlerden daha doğrudur (Cirulis ve Brigmanis, 2013: 77).

Jeodezik çözümünün bir formülünü seçerken, programın uzunluğunu, yani bilgisayarda trigonometrik ve diğer gerekli fonksiyonlarla birlikte işlemci yükünü dikkate almak birincil önemdedir. Bilgisayar sisteminin sadece bir doğrudan ve bir tersine alt programa sahip olması avantajlıdır. Her iki alt programda birkaç cm'den 20.000 km'ye kadar herhangi bir uzunlukta tam doğruluk sağlamalıdır (Vincety, 1975: 88).

Deneyisel çalışmalar yaklaşık 1.500 km'ye kadar olan hatlar için Browring'in tersine, Sodano'nun doğrudan ve tersine veya Rainsford tarafından verilen McCaw'ın doğrudan alt programları gibi iterative olmayan çözümlerin Vincety'nin iterative çözümünden daha fazla yer kapladıklarını ve bazılarının daha yavaş çalıştıklarını göstermiştir. Bu doğrudan ve tersine çözüm, Rainsford'un tersine formülünden geliştirilmiştir. Doğrudan çözüm, Rapp yaklaşımını kullanarak tersine alt program ters

çevrilerek elde edilmiştir. Rainsford'un f4'deki önemsiz terimleri ihmal edildi ama u8'deki en önemli terimler muhafaza edilmiştir (Vincety, 1975: 88).

Önerilen çözümlerin yoğunluğu, eliptik terimleri hesaplamak için iç içe geçmiş denklemlerin ve üç geometrik fonksiyonun kullanılmasından kaynaklanmaktadır: Sinüs, Cosinüs ve Arktanjan. İç içe yerleştirme, depolamalar ve ara sonuçların alınmasını kapsayan işlem sayısını, program uzunluğunu, yürütme süresini ve yetersizlik olasılığını azaltır (Vincety, 1975: 88).

Notasyon

a,b elipsoidin büyük ve küçük yarı eksenleri

f, düzleştirme=(a-b)/a

φ , jeodezik enlem, ekvatorun pozitif kuzeyi

L, boylam farkı, pozitif doğu

S, jeodezik uzunluk

α_1, α_2 jeodeziğin güney açıları, kuzeyden saat yönünde

α , ekvatordaki jeodeziğin güney açısı

$$U^2 = \cos^2 \alpha \times (a^2 - b^2) / b^2$$

Denklem 8

U, indirgenmiş enlem, $\tan U = (1-f) \tan \varphi$ ile tanımlanır

λ , bir yardımcı küredeki boylam farkı

σ , küredeki P1 ve P2 arasındaki açısal fark

σ_1 , ekvator dan P1'e küre üzerindeki açısal mesafe

σ_m , ekvator dan hattın orta noktasına kadar olan küre üzerindeki açısal mesafe

Doğrudan Formül

$$\tan \sigma_1 = \tan U_1 / \cos \alpha_1$$

Denklem 9

$$\sin \alpha = \cos U_1 \times \sin \alpha_1$$

Denklem 10

$$A = 1 + \frac{U^2}{16.384} \times \{4.096 + U^2 \times [-768 + U^2 \times (320 - 175 \times U^2)]\}$$

Denklem 11

$$B = \frac{U}{1.24} \times \{256 + U^2 \times [-128 + U^2 \times (74 - 47 \times U^2)]\}$$

Denklem 12

$$2 \times \sigma_m = 2 \times \sigma_1 + \sigma$$

Denklem 13

$$\Delta \sigma = B \times \sin \sigma \times \left\{ \cos 2 \times \sigma_m + \frac{B}{4} \times [\cos \sigma \times (-1 + 2 \times \cos^2 2 \times \sigma_m)] \right\}$$

Denklem 14

$$\sigma = \frac{S}{b \times A} + \Delta \sigma$$

Denklem 15

Eşitlik 13, 14 ve 15 σ 'da ihmal edilebilir bir değişiklik olana kadar tekrarlandı. σ 'nın ilk yaklaşımı denklem 15'nin ilk terimidir.

$$\tan \varphi = \frac{\sin U_1 \times \cos \sigma + \cos U_1 \times \sin \sigma \times \cos \alpha_1}{(1-f) \times \sqrt{\sin^2 \alpha + (\sin U_1 \times \sin \sigma - \cos U_1 \times \cos \sigma \times \cos \alpha_1)^2}}$$

Denklem 16

$$\tan \lambda = \frac{\sin \sigma \times \sin \alpha_1}{\cos U_1 \times \cos \sigma - \sin U_1 \times \sin \sigma \times \cos \alpha_1} \quad \text{Denklem 17}$$

$$C = \frac{f}{16} \times \cos^2 \alpha \times [4 + f \times (4 - 3 \times \cos^2 \alpha)] \quad \text{Denklem 18}$$

$$L = \lambda - (1 - C) \times f \times \sin \alpha \times \{ \sigma + C \times \sin \sigma \times [\cos 2 \times \sigma_m + C \times \cos \sigma \times (-1 + 2 \times \cos^2 2 \times \sigma_m)] \} \quad \text{Denklem 19}$$

$$\tan \alpha_2 = \frac{\sin \alpha}{-\sin U_1 \times \sin \sigma + \cos U_1 \times \cos \sigma \times \cos \alpha_1} \quad \text{Denklem 20}$$

Tersine Formül

$$\lambda = L \quad \text{Denklem 21}$$

$$\sin^2 \sigma = (\cos U_2 \times \sin \lambda)^2 + (\cos U_1 \times \sin U_2 - \sin U_1 \times \cos U_2 \times \cos \lambda)^2 \quad \text{Denklem 22}$$

$$\cos \sigma = \sin U_1 \times \sin U_2 + \cos U_1 \times \cos U_2 \times \cos \lambda \quad \text{Denklem 23}$$

$$\tan \sigma = \frac{\sin \sigma}{\cos \sigma} \quad \text{Denklem 24}$$

$$\sin \alpha = \cos U_1 \times \cos U_2 \times \sin \lambda / \sin \sigma \quad \text{Denklem 25}$$

$$\cos 2 \times \sigma_m = \cos \sigma - 2 \times \sin U_1 \times \sin U_2 / \cos^2 \alpha \quad \text{Denklem 26}$$

λ , 18 ve 19. denklemden elde edildi. Bu prosedür $\Delta\lambda$ 'daki değişim önemsiz olana kadar 22. Denklem ile başlanarak tekrarlandı.

$$S = b \times A \times (\sigma - \Delta\sigma) \quad \text{Denklem 27}$$

1.3. BAŞLANGIÇ-VARIŞ MATRİSLERİNİN TAHMİNLENMESİ

Başlangıç-Variş matrisi tahmini için çeşitli veri toplama yöntemleri mevcuttur. Bu yöntemler geleneksel veri toplama yöntemleri ve yeni veri toplama yöntemleri olmak üzere iki grupta incelenebilir.

1.3.1. Geleneksel Veri Toplama Yöntemleri

Yıllardır, farklı alanlarda iyileştirmelere yol açabilecek karayolu trafik verilerini toplamak için birçok yöntem kullanılmıştır. Geleneksel yöntemler seyahat anketleri ve trafik sayımları olmak üzere iki ana kategoriye ayrılabilir.

1.3.1.1. Anketler

Yıllar boyunca seyahat anketleri ulaştırma planlamacıları ve politika yapıcılar için önemli bir rol oynamıştır. Yol kenarı anketleri, araç içi anketler ve hane halkı seyahat anketi, seyahat bilgileri elde etmek için gerçekleştirilen anketlerden

bazılarıdır. Hanehalkı Seyahat Anketleri (HSA), postayla veya kişisel görüşme anketi şeklinde gerçekleştirilir. Son yıllarda, telefon görüşmeleri ve bilgisayar destekli yöntemler gibi diğer yöntemler bulunmuş ve kademeli olarak geleneksel anket yöntemlerinin yerini almıştır. Bilgisayar teknolojisi devrimi ile, anketörlerin sorumluluğunu azaltan ve toplanan verilerin doğruluğunu arttıran bilgisayar destekli telefon görüşmeleri sayesinde gittikçe daha fazla seyahat anketi yapıldı (Wolf vd., 2001; Wolf, 2004'den aktaran Alsger vd., 2016: 12; Safi vd., 2014).

Seyahat anketi bilgileri, BV matrislerinin oluşturulmasında ana kaynak olmuştur. 1995, 2001 ve 2009 yıllarında Ulusal çapta kişisel taşımacılık anketleri seyahat davranışını tanımlamak ve BV matrisleri gibi seyahat bilgileri elde etmek için kullanılmıştır (Hu ve Young, 1999; Hu ve Reuscher, 2004; Santos vd., 2011; Stopher vd., 2011).

Anket yöntemlerinin para, zaman ve insan kaynakları açısından yüksek maliyet gibi bazı önemli eksiklikleri vardır. Ayrıca, veri kalitesi, tamamen görüşülen kişilerin hatıralarına ve görüşülen kişilerin kayıtlarına bağlı olduğu için endişe vericidir. Ek olarak, örneklem büyüklüğü çok düşüktür ve yüksek maliyet nedeniyle her 5-10 yılda bir anketler yapılmaktadır (Casas ve Arce, 1999'den aktaran Alsger, 2016: 13; Ton ve Hensher, 2002; Transportation Research Board's Travel Survey Methods Committee, 2008; Ashley vd., 2009; Carrion vd., 2014).

1.3.1.2. Trafik Sayımları

Bir noktadan geçen veya bir kavşağa giren araçların sayısı karayolu operasyonlarının analizinde sıklıkla kullanılır. Manuel gözlem ve otomatik kayıt, trafik sayımlarından BV matrisleri gibi seyahat verilerini toplamanın iki yöntemidir (Leduc, 2008).

Son 35 yıl içerisinde trafik sayımlarını kullanarak BV matrisi tahmin yöntemi en fazla tercih edilen ve BV matrisi tahmininde sıklıkla kullanılan yöntem olmuştur. Trafik sayım verilerinin düşük maliyetle ulaştırma ağlarındaki linklerden elde edilmesinin mümkün olması bu yöntemin tercih edilmesinin en büyük nedenidir (Ağaoğlu, 2009: 130).

Düğüm ve linklerden oluşan, bir yol ağı tarafından birbirlerine bağlanan, N bölgeye bölünmüş bir çalışma alanı için, yolculuk matrisi, N^2 hücreden veya bölge içi yolculuklar dikkate alınmadığı durumda ise, $(N^2 - N)$ hücreden oluşur. Trafik

sayımlarını kullanarak, bir ulaşım talep modeli tahmini için, en önemli safha, her bir başlangıçtan her bir varışa olan yolculukların, takip ettiği yolların belirlenmesidir. p_{ij}^a değişkeni, i bölgesinden j bölgesine yapılan yolculukların, a linkini tercih etme olasılığını, yani link ağırlık matrislerini tanımlamak için kullanılır. Böylece, belirli bir a linki için (V_a) akımı, bölgeler arasındaki bütün yolculukların, bu linke olan katkılarının toplamı olmaktadır. Bu durum, matematik ifade olarak aşağıdaki şekilde gösterilebilir (Ortuzar ve Willumsen, 1990'dan aktaran Ağaoğlu, 2009: 130).

$$V_a = \sum_{ij} T_{ij} \times p_{ij}^a, \quad 0 \leq p_{ij}^a \leq 1$$

Denklem 28

Burada T_{ij} = i bölgesinden j bölgesine yapılan yolculuk miktarı

a: link numarası

V_a = a linki üzerindeki tahmin edilen akım (taşıt/saat)

p_{ij}^a = i bölgesinden j bölgesine yapılan yolculukların, a linkini tercih etme olasılığıdır.

p_{ij}^a matrisi, yolculuk atama teknikleri tarafından belirlenmektedir. Basit olarak “ya hep ya hiç” atamasından, daha karmaşık “denge” atamalarına kadar sınıflandırılabilen, çeşitli atama teknikleri kullanılmaktadır. Denklem 28'den de görüleceği üzere, p_{ij}^a değerleri ve gözlenen trafik hacimlerinin tamamı verildiğinde, yolculuk matrisinin içindeki, T_{ij} değerleri bilinmeyen olarak kalacaktır. Bunların bulunabilmesi için, bilinmeyen sayısı kadar denklem yazılması gereklidir. Bu mümkün değildir. Çünkü, gözlenen trafik sayımları, bilinmeyen T_{ij} 'lerin sayısından çok azdır. Bu nedenle, matris tahmin problemi için, tek çözümün belirlenmesi imkansızdır. Bunun sonucunda da, gerçek yolculuk matrisi elde edilemeyecektir. Bu yüzden, problemi çözmek için, ilave verilere (başlangıç bilgisi) ve/veya yolculuk davranışı hakkında kabullere ihtiyaç vardır (Abrahamsson, 1998). Trafik sayımlarını kullanarak BV matrisi tahmini yöntemleri genel olarak, zamana bağlı olmayan (statik) ve zamana bağlı (dinamik) olmak üzere iki grup altında toplanmaktadır. Ayrıca, tıkanıklık etkisinin olup olmamasına göre belirlenen yolculuk atama tekniklerine göre de sınıflandırılması mümkündür (Peterson, 2007).

Trafik sayım verilerini kullanarak BV matrisi tahmin edilmesindeki amaç, tahmin edilen BV matrisi ile ilkel matris ve gözlenen link akımları ile BV matrisinin ağ üzerine atanmasıyla elde edilen link akımları arasındaki sapmaların minimize edilmesidir. Bu sapmaların belirlenmesi için ilk yaklaşım maksimum entropi

yaklaşımıdır. Maksimum entropi formülasyonu minimum bilgi prensibinden türetilerek Van Zuylen (1978) tarafından önerilmiştir (Van Zuylen ve Willumsen, 1980).

Sapmaların belirlenmesinde kullanılan ikinci yaklaşım maksimum olasılık yaklaşımıdır. Yukarıda anlatılan “Entropi Maksimizasyonu” modellerinde ilkel matris, model formülasyonu için gerekli değildir. İlkel matris yerine bütün elemanları aynı olan bir matris kullanılabilir. Böyle bir matris kullanılarak tahmin edilen BV matrisi gerçek durumu yansıtmada başarısız olmaktadır. BV matrisinin, ağ üzerine atanması sonucunda bulunan link hacimleri ile gözlenen link hacim değerleri birbirine yakın bulunması mümkündür. Fakat buna karşılık ilkel matris içerisindeki her BV çiftine aynı oranda değer verildiği ve model bu değerler üzerinde düzenlemeler yaparak BV matrisini tahmin ettiği için bulunan matris ile gerçek değerler arasında büyük sapmalar ortaya çıkmaktadır. Bu durumu ortadan kaldırmak ve gerçeğe daha yakın bir BV matrisi tahmin etmek amacıyla “Maksimum Olasılık” yöntemi geliştirilmiştir (Spiess, 1987’den aktaran Ağaoğlu, 2009: 130; Nihan ve Davis, 1989; Lo ve Chan, 2003). Son on yıl içerisinde tahmin modellerinde yaygın olarak kullanılan sapma belirleme ölçüsü, en küçük kareler formülasyonudur. Bu modellerde her bir link gözlemine verilen önemi belirtmek için varyans değeri kullanılmaktadır. Farklı linklerdeki gözlemler arasındaki kovaryans değerleri dikkate alındığında bu model geliştirilmiş en küçük kareler modeli olarak anılmaktadır (Casetta, 1984’den aktaran Ağaoğlu, 2009: 130; Hendrickson ve McNeil, 1984; Hendrickson ve McNeil, 1985). BV matrisinin tahmin modellerinin sınıflandırılmasında ikinci olarak, atama türü dikkate alınmaktadır. Trafik sayımlarını kullanarak BV matrisi tahminindeki en önemli nokta kullanılan atama tekniğidir. Yani, i bölgesinden j bölgesine olan yolculukların, ulaştırma ağı üzerinde hangi yolu kullanarak gerçekleşeceği. Tıkanıklık etkisinin dikkate alınıp alınmaması durumuna bağlı olarak atama tekniği belirlenmektedir. Atama türleri, orantılı atama ve denge ataması olarak iki grup altında sınıflandırılmaktadır (Abrahamsson, 1998). Orantılı atama durumunda tıkanıklık etkisi dikkate alınmamaktadır. Taşıtların güzergah tercihleri, linkler üzerindeki trafik yükünden bağımsızdır. Denge ataması durumunda ise, tıkanıklık etkisi hesaba katılmaktadır. Taşıtların güzergah seçimleri linkler üzerindeki trafik yüküne bağlıdır. Dolayısıyla, link tercih olasılıklarının BV matrisi tahmin probleminin içerisinde belirlenmesi gereklidir.

1.3.2. Yeni Veri Toplama Yöntemleri

Küresel Konumlandırma Sistemi (GPS) ve akıllı kart verileri olarak anılan, nispeten yeni veri toplama yöntemleri son zamanlarda seyahat bilgi kaynakları olarak tanıtılmıştır. Bu sistemler, bir navigasyon uygulaması veya toplu taşımada bir ücret toplama yöntemi olarak kullanılmasının yanı sıra veri toplama yöntemleri olarak da kullanılabilir (Kaplan ve Hegarty, 2005; Pelletier vd., 2011).

1.3.2.1. Coğrafi Konumlama Sistemi (GPS) Verileri

Taşıt filosu yönetimi ve takibi, ulaşım alt yapısı verilerinin toplanması ve haritalanması, olay yönetimi ve izleme ile araç navigasyon sistemleri için taşıma alanında GPS cihazları kullanılmıştır (Feng ve Law, 2002; Mintsis vd., 2004).

Bu sistemler aynı zamanda bir toplu taşıma işletmecisinin yöneticileri tarafından bir Otomatik Araç Konumu (Automatic Vehicle Location - AVL) sistemi seçme ve uygulamada gerekli olan bilgileri sağlamıştır (Stone vd., 1999).

Son çalışmalar GPS cihazlarından toplanan verileri kullanarak katılımcıların seyahat özelliklerini otomatik olarak belirlemeye çalışmıştır (Stopher vd., 2010; Gong vd., 2012).

GPS teknolojisi aşağıdaki ana amaçlarla kullanılmıştır: eksik beyanların tahmini (Pierce vd., 2003; Bricka ve Bhat, 2006), seyahat davranış analizi (Stopher vd., 2008), geleneksel davranışların değiştirilmesi (Cottrill vd., 2013; Carrion vd., 2014) ve yolculuk oranı faktörü doğrulaması (Pierce vd, 2003; Systematics, 2007).

1.3.2.2. Akıllı Kart Verileri

Mikroçip içeren plastik bir kart kavramı, 1968'de iki Alman mucit, Dethloff ve Grotrupp tarafından geliştirilmiştir (Shelfer ve Procaccino, 2002). Almanların ilk akıllı kartı geliştirmesinden sonra, Japonlar lideri takip ederek akıllı kartın kendi versiyonunu tescil ettiler (Attoh-Okine ve Shen, 1995). Bu akıllı kart sistemleri, 1982'den beri piyasada ticari faaliyetler, sağlık hizmetleri, posta ve telgraf hizmetleri alanlarında kullanılmaktadır (Attoh-Okine ve Shen, 1995). Akıllı kart otomatik ücret toplama sistemleri toplu taşıma araçlarında toplu taşıma kuruluşları tarafından yaygın olarak kullanılmaktadır. Bu sistemler tüm dünyada uygulanmıştır. Londra (İngiltere),

Montreal (Kanada), New York ve Chicago (ABD), Santiago (Şili), Singapur (Singapur) ve Brisbane (Avustralya), toplu taşıma ağlarında akıllı kart sistemlerini uygulayan şehirlerden bazılarıdır. (Munizaga vd., 2010; Pelletier vd., 2011).

Akıllı kart otobüste okunduktan sonra, işlemle ilgili bilgiler bir yerleşik cihaza depolanır ve ardından otobüs garaja geri döndüğünde merkezi sunucuya asenkron olarak aktarılır. Akıllı kart sistemleri toplu taşıma şirketleri tarafından geleneksel manyetik kartın veya kağıt biletlerin yerine geçerli bir ödeme (Blythe, 2004), güvenli bir kullanıcı doğrulama ve ücret ödeme yöntemi (Trépanier vd., 2004) olarak kullanılmıştır. Ek olarak, bu akıllı kart sistemleri, verilerin kalitesini iyileştirme, toplu taşımaya daha modern bir görünüm sağlama, yenilikçi ve esnek ücretlendirme için yeni fırsatlar sağlama potansiyeline sahiptir (Dempsey, 2015).

Geçtiğimiz birkaç yıl boyunca transit acenteleri ve toplu taşıma yetkilileri, ulaşım hizmetlerini ve altyapısını iyileştirmek, mevcut ve gelecekteki talebi planlamak ve analiz etmek, toplu taşıma hizmetlerini yönetmek için akıllı kart verilerini yaygın olarak kullanıyorlar. Akıllı kartların kullanılmasının birincil avantajı, değerli bir ödeme seçeneği olarak orijinal kullanımlarına ek olarak, toplu taşıma şirketleri ve araştırmacılar için yüksek kalitede ve miktarda bilgi kaynağı sağlamasıdır (McDonald, 2000; Pelletier vd, 2011). Akıllı kart sistemleri toplu taşıma kuruluşları tarafından maliyet azaltma, ücret toplama, veri kalitesi ve miktarını artırma, sık veri güncelleme, yolcu rahatlığı sağlama ve bekleme zamanını azaltma amaçları için kullanılmıştır.

Akıllı kart verilerini kullanan B-V tahmin yöntemlerinin çoğu, daha önce açıklandığı gibi, yolcu zincirleme yönteminin ve onun varsayımlarının temel algoritmasından yola çıkılarak yapılmıştır. Bu yöntem, bir sonraki yolculuğun biniş durağına en yakın hat durağının iniş durağı olarak belirlenmesini esas alan bir yöntemdir.


1.4. BAŞLANGIÇ-VARIŞ MATRİSLERİNDEN HAT TALEBİNİN HESAPLANMASI

BV matrislerinde satır ve sütunlar bir durağı simgeler. Bu iki durak arasında seyahat eden yolcu sayısı söz konusu satır ve sütunun kesiştiği hücrede yer alır. Başlangıç-Variş Matrisine bir örnek Tablo 1'de gösterilmiştir.

Tablo 1: Başlangıç-Variş Matrisi Örneği

	Durak1	Durak2	Durak3	Durak4	Durak5
Durak1		3	12	25	15
Durak2	3		4	10	20
Durak3	12	4		5	18
Durak4	25	10	5		20
Durak5	35	20	18	20	

BV Matrisleri yardımıyla hatların maksimum talep düzeyleri hesaplanabilir. Matriste seçilen hatta ait iki durak arasında seyahat eden kişi sayısı bu iki durak arasındaki duraklarda otobüsteki yolcu sayısına ilave edilir. Maksimum talep düzeyinin belirlenmesi Şekil 6’da gösterilmiştir.

Şekil 6: Maksimum Hat Talebinin Belirlenmesi.

Durak1-Durak2: 3+12+25+15= 55 kişi

Durak2-Durak3: 12+25+15+4+10+20=86 kişi

Durak3-Durak4: 25+15+10+20+5+18= 93 kişi

Durak4-Durak5: 15+18+20+20= 73 kişi

Durak1’den tüm duraklara giden yolcuların toplam sayısı durak1-durak2 arasındaki yolda otobüsteki yolcu sayısına eşit olacaktır. Benzer şekilde 2. Duraktan sonraki duraklara giden yolcu sayısına ilaveten 1. Duraktan 2.durak dışındaki duraklara giden yolcular da durak2-durak3 arasındaki yolculukta otobüste yer alır. Benzer şekilde duraklar arasındaki yolculuklarda otobüslerde ne kadar yolcu olacağı hesaplanır. En yüksek yolcu sayısı o hat için maksimum talebi verecektir.

1.5. SEFER SIKLIĞI OPTİMİZASYONU (SEFER ÇİZELGELEME)

Vuchic 2005 yılında geliştirdiği matematiksel bağıntı ile her hattın zirve saatindeki maksimum yolcu sayısı ve otobüs kapasitesi yardımıyla her hattın optimum sefer sıklığının denklem 29 ile bulunabileceğini göstermiştir (Vuchic, 2005: 51).

$$f_i = \frac{P_{di}}{\alpha_i \cdot C_{vi} \cdot n_i}, P_{di} = P_{\max i} \cdot PHC_i$$

Denklem 29

Denklemlerdeki P_{di} “i”nci hatta ait tasarım yolcu hacmini; α_i , yükleme parametresini; C_{vi} , kullanılan aracın kapasitesini; n_i , tek bir sefer için kullanılan araçtaki bağımsız parça sayısını; P_{maxi} , maksimum yolcu yükünün bulunduğu kesimdeki yolcu hacmini; PHC_i ise zirve saat katsayısını göstermektedir. Zirve saat katsayısı (PHC), zirve saat içerisindeki yolcu hacmi değişimini(dalgalanma) ifade etmektedir. Bu katsayı dikkate alınarak aynı saat içerisinde hareket eden fakat aşırı yolcu yüküne sahip olan otobüslerin önüne geçilmesi amaçlanmaktadır. Zirve saat katsayısı (PHC), denklem 30 ile elde edilmektedir (Vuchic, 2005: 48).

$$PHC = \frac{4.P_{15}}{P_{max}}$$

Denklem 30

Denklemlerdeki P_{15} , 15 dakikalık en yüksek yolcu sayısını P_{max} , maksimum yolcu yükünün bulunduğu kesimdeki yolcu hacmini ifade etmektedir. Zirve saat katsayısı istenirse 15 dakikadan daha küçük zaman dilimleri için de hesaplanarak kullanılabilir. Zirve saat katsayısı teorik olarak 1 ile 4 arasında değerler almaktadır.

Selçuk ALP 2008’deki doktora tezindeki modelleri oluştururken İETT Etüd ve Planlama Dairesi tarafından hazırlatılan bir çalışmadan yararlanmıştır. Modeller oluşturulurken her bir otobüs hattının ele alınan zaman dilimindeki sefer sayısı, karar değişkenleri olarak kabul edilmiştir. Sefer sayılarının, özellikleri gereğince tamsayı olmaları gerekmektedir. Söz konusu karar değişkenleri oluşturulurken İETT’nin Kağıthane otobüs garajında mevcut olan 3 farklı tipteki otobüsleri dikkate alınmıştır. Kapasite ve talep değerlerini kullanan altı farklı hedef programlama modeli geliştirilmiş ve çözülmüştür. Yalnızca pozitif sapmaların gözlenmesi modellerdeki mutlak kısıtların gerçekleştiği ve hedeflerin aşıldığını ifade etmektedir. Modellerin tamamında pozitif sapmalar görülmüştür. Bu sapmalar atıl kapasite veya atıl zamanı göstermektedir. Süre kısıtlarını dikkate alan diğer 5 modelde optimum sefer sıklığı 640 olarak hesaplanırken, süre kısıtlarını dikkate almayan tek hedefli modelde optimum sefer sıklığı 606 olarak hesaplanmıştır. Sonuç olarak yazar tarafından hedef programlamanın optimum sefer sıklığı belirlemek amacıyla kullanılabileceği ifade edilmiştir (Alp, 2008: 148-160).

Nurcan Uludağ’ın 2010’daki doktora tezinde, Lozan ve Montrö duraklarından geçen 26 hattın verileri derlenmiş, sabah 08:00-11:00 saatleri arasındaki talep verileri kullanılmıştır. Yazar 26 hattın kapasite ve talep bilgileriyle bir hedef programlama

modeli kurmuş ve çözmüştür. Hedef programlama neticesinde 26 hat için sefer sıklıkları 225'den, 167'ye düşmüştür (Uludağ, 2010: 57-62).

Alper Deri 2012'deki yüksek lisans tezinde, otobüs hatlarının talep ve kapasitelerini dikkate alarak hedef programlama modeliyle optimum sefer sıklığını belirlemiştir. Çalışmada İzmir güney-batı bölgesi ile Konak-Halkapınar arasında hizmet veren otobüs hatları örneği üzerinde durulmuştur. Sabah zirve saati içerisinde kent merkezine gidiş yönündeki talebe cevap verecek en uygun otobüs sefer sıklıkları, hafta ortası bir güne ait yolculuk verileri kullanılarak Doğrusal Hedef Programlama (DHP) yöntemi ve ampirik formüller yardımıyla hesaplanmış ve elde edilen sefer sayıları işletmenin yaptığı sefer sayılarıyla karşılaştırılmıştır. Mevcut sefer sıklıklarında 37.456 atıl kapasite (yolcu sayısı) varken, ampirik formülde 15.756'ya ve hedef programlama modelinde 12.270'e düşmüştür. Bu durum hedef programlama ile verimlilik düzeyi daha yüksek olan sefer çizelgeleri oluşturabileceğini göstermiştir (Deri, 2012: 121-124).

Sun ve arkadaşları yolcu bekleme sürelerini ve işletme maliyetini minimize eden bir matematiksel model geliştirmiş ve Lagrange dual optimizasyon yöntemi ile çözümünü gerçekleştirmiştir. Yazarlar bu yöntemin yolcuların aktarma ihtiyaçlarını tatmin eden etkin tren çizelgeleri oluşturmak için kullanılabileceğini raporlamışlardır (Sun vd., 2013).

Xu ve arkadaşları tren sefer sıklığı optimizasyonu için bir parçacık sürü optimizasyonu modeli geliştirmişlerdir. Bu modeli Şangay metrosunun belirli bir bölümüne uygulamışlardır. Yazarlar, simülasyon sonuçlarına göre yöntemin yolculuk zamanında ihmal edilebilir bir artışa neden olurken hattaki sefer sıklıklarını önemli ölçüde azalttığını raporlamışlardır (Xu vd., 2014).

Schmaranzer ve arkadaşları Viennese metro sistemi için simülasyon tabanlı optimizasyon çalışması yapmışlardır. Bu çalışmada poisson dağılımına göre yolcu gelişleri oluşturulmuş ve başlangıç-varış matrisleri hesaplanarak hizmet kalitesi ve maliyet arasında denge kuran iki ölçütlü optimizasyon yapılmıştır. Yazarlar optimizasyon için çeşitli genetik algoritma modellerini test etmiş ve en iyi sonucu kovaryans matris adaptasyon evrim stratejisinin verdiğini raporlamışlardır (Schmaranzer vd., 2018).

İKİNCİ BÖLÜM

VERİ MADENCİLİĞİ

Çalışmanın bu bölümünde, veri madenciliği kavramı açıklanmış, veri madenciliğinin kullanım alanları, veri madenciliğinde kullanılan yöntemler ve veri madenciliği süreci kısaca özetlenmiştir.

2.1. VERİ MADENCİLİĞİ KAVRAMI

Veri madenciliği en basit şekilde önceden bilinmeyen, geçerli ve uygulanabilir bilginin veri yığınlarından dinamik bir süreç ile elde edilmesi işlemidir. Bu süreçte kümeleme, veri özetleme sınıflama kurallarının öğrenilmesi, bağımlılık ağlarının bulunması, değişkenlik analizi ve anomali tespiti gibi farklı birçok teknik kullanılmaktadır (Baykal, 2006: 96).

Veri madenciliği, istatistiksel analiz teknikleri ve yapay zekâ tekniklerinden bir arada faydalanarak çok sayıda durum ve değişkenden oluşan veri yığınları içinde gizli kalmış bilgilerin açığa çıkarılması ve verinin karar destek tabanlı bilgiye dönüştürülmesi sürecidir (Yılmaz, 2009: 3).

2.2. VERİ MADENCİLİĞİNİN UYGULAMA ALANLARI

Veri madenciliğini verinin üretilip kayıt altına alındığı hemen her alanda kullanmak mümkündür. Sağlık, endüstri, mühendislik, üretim yönetimi, finansman yönetimi, muhasebe, perakendecilik, pazarlama, bankacılık ve eğitim alanları veri madenciliğinin yoğun olarak kullanıldığı alanlardır (Ertuğrul vd., 2013: 98-99).

2.2.1. Sağlık Alanında Uygulamalar

Sağlık sektöründe teşhis sistemleri için yapay zeka teknikleri, uzman sistemler ve veri madenciliği yaygınlaşmaktadır. Bu alanda yapılan çalışmalar ilaçların geliştirilmesi, ilaç etkilerinin tespit edilmesi, hasta test sonuçlarının tahmin edilmesi, hastalıkların önceden teşhis ve tedavi edilmesinde önemli bir yere sahiptir.

Örneğin Güllüoğlu 2011’de yayınlattığı makalesinde göğüs, akciğer ve bağırsak kanserlerinin erken teşhisi için bir yapay sinir ağı uygulaması gerçekleştirmiş ve başarılı sonuçlar almıştır (Güllüoğlu, 2011).

Doğan 2017 yılında yayınlanan lisansüstü tezlerin incelendiği makalesinde 13 tıp tezinde veri madenciliği algoritmalarının kullanıldığını raporlamıştır. Bu tezlerin 7'sinin yüksek lisans, 6'sının ise doktora tezi olduğu yazar tarafından raporlanmıştır (Doğan, 2017).

Koyuncugil ve Özgülbaş 2009'da yayınlanan makalelerinde tıpta veri madenciliğinin kullanım imkanlarını değerlendirmişlerdir. Yazarlar kronik hastalıkların ortaya çıkış nedenlerini anlamak için temel bileşenler analizi, faktör analizi ve lojistik regresyon analizlerinin kullanılabileceğini, laboratuvar sonuçlarının kümeleme ve birliktelik kuralları ile analizi neticesinde anormalliklerin tespitinin ve hastalık teşhisinin yapılabileceğini, hizmet kalitesini arttırmak için risk analizlerinde çeşitli veri madenciliği uygulamaları yapılabileceğini belirtmişlerdir. Bunun dışında yolsuzluk ve suistimallerin ortaya çıkartılmasında, finansal performans değerlendirmede ve yönetsel karar destek sistemlerinde veri madenciliği yöntemlerinin uygulanabileceğini göstermişlerdir (Koyuncugil ve Özgülbaş, 2009).

2.2.2. Endüstri ve Mühendislik Alanında Uygulamalar

Endüstri ve mühendislik alanında veri madenciliğinin kullanımı oldukça yaygındır. Üretim süreçlerinin kontrol edilmesinde, kalite kontrol analizlerinde, arıza teşhisinde, ürün tasarımında, robotikte, çizelgeleme problemlerinin çözümünde, her türlü tahmin problemlerinde, kuruluş yeri seçimi ve fabrika düzenleme problemlerinde, sistem performanslarına etki eden faktörlerin ve kuralların çıkarılmasında veri madenciliği algoritmalarından yararlanılmaktadır.

Kim ve arkadaşları 2012'de yayınlanan makalelerinde, çok değişkenli ve otokorelasyonlu süreçlerde etkin bir izleme sağlamak için istatistiksel süreç kontrol teknikleriyle en gelişmiş veri madenciliği algoritmalarını birleştirdiklerini raporlamışlardır. Çeşitli senaryolar için yapılan simülasyonlarda veri madenciliği modeli tabanlı kontrol kartlarının geleneksel zaman serisi modeli tabanlı kontrol kartlarından daha iyi performans gösterdiğini raporlamışlardır (Kim vd., 2012).

Németh ve Michal'çonok 2016'da yayınlanan araştırma raporlarında, süreç kontrol sistemlerinden gelen arıza verilerini hazırlamak ve dönüştürmek için özellikle kümeleme olmak üzere veri madenciliği algoritmalarının uygulandığı bir yöntem önermişlerdir (Németh ve Michal'çonok, 2016).

Ghosh ve Maiti 2014’de yayınlanan makalelerinde hata teşhisi ve kalite iyileştirme için geçmiş dönem verilerini kullanan veri madenciliği ile desteklenmiş DMAIC yöntemini önermiştir. DMAIC (Define – Measure – Analyze – Improve – Control), altı sigmanın tanımla-ölç-analiz et-geliştir-kontrol et yöntemidir. Önerilen yapıda, sınıflandırma ve regresyon ağacı ve ki-kare otomatik etkileşim algılama olarak isimlendirilen iki karar ağacı kullanılmıştır. Deney tasarımı uygulayamayan bir şirkette bu yöntem kullanılmış ve döküm kusurlarında önemli bir azalma sağlanmıştır. Bu sonuçlara göre, yazarlar yöntemin kalite iyileştirmede kullanılabileceğini ifade etmişlerdir (Ghosh ve Maiti, 2014).

Bae ve Kim 2011’deki çalışmalarında dijital kamera tasarımı için c5.0 karar ağacı ve Apriori birliktelik kuralları veri madenciliği yöntemlerini kullanmışlardır. Bu algoritmalar vasıtasıyla ortaya çıkartılan bilgiler, ürün tasarımı ve pazarlama için olası öneriler sunmak amacıyla ürün haritaları üzerinde bilgi modelleri ve kurallar olarak gösterilmiştir. Bu çalışmada müşterilerden ürün tasarım bilgileri çıkarmak için birliktelik kurallarının ve C5.0 karar ağacının ortaya çıkardığı kuralların birleştirilmesi önerilmiştir (Bae ve Kim, 2011).

Kumara ve Rao 2009 yılındaki makalelerinde, büyük bir dizi akış tipi çizelgeden bilgi çıkarmak amacıyla yeni bir veri madenciliği yöntemi önermişlerdir. Yazarlar, çizelgeleme yapan genetik algoritma operatörleri de içeren bir karınca kolonisi optimizasyon algoritmasının oluşturduğu verilerdeki desenleri araştıran ve karınca kolonisi optimizasyonunun çizelgesine yakın sonuçlar veren bir çizelgeleme kural dizisi geliştirmek amacıyla çalışmayı yaptıklarını duyurmuşlardır. Karınca kolonisi optimizasyonunun oluşturduğu verilerden bilgi çıkarmak için yazarlar karar ağacı algoritması kullanmışlardır. Veri madenciliği sistemleri tipik olarak IF-THEN kuralları ile temsil edilen koşullu ilişkileri kullanır ve üretim yöneticilerinin çeşitli objektif fonksiyonlara ve kısıtlamalara dayanan akış tipi çizelgeleme ile ilgili kararları kolayca almalarına olanak sağlar. Deneysel sonuçlar veri madenciliği yöntemlerinin karınca kolonisi optimizasyonu ile oluşturulan akış tipi çizelgelerden çizelgeleme kurallarını öğrenebileceğini göstermiştir (Kumara ve Rao, 2009).

Moradi ve arkadaşları 2016 yılındaki yayınlarında robotik alanındaki veri madenciliği uygulamaları için bir yazın özeti sunmuşlardır. Bu çalışmada, yazındaki çalışmalar; robot kontrolü için veri madenciliği, robot görüşü için veri madenciliği,

robot öğrenmesi için veri madenciliği, robot davranışı için veri madenciliği başlıkları altında incelenmiştir (Moradi vd., 2016).

Medhi ve arkadaşları 2014’de sundukları bildiride, firmaların pazar bilgi edinimi için kullandıkları bilgi süreçlerine dayalı sınıflama için kendi kendini organize eden haritalar ve Kohonen’in haritalarını kullandıklarını bildirmişlerdir. Yazarlar, Alman endüstrilerinin Dünya Bankası kurumsal anketinden (2005) elde edilen verileri kullanarak, kullanılan bilgi süreçleri temelinde üç ayrı sektör kümesini üretmişlerdir. Yazarlar, tedarikçi performans verileri ile sinir ağlarını eğitmişlerdir ve bu ağların sadece mevcut tedarikçilerin sınıflandırılması için değil, aynı zamanda yeni tedarikçilerin mevcut bir grup veya sınıfa dahil edilmesi için de kullanılabileceğini raporlamışlardır (Medhi vd., 2014).

Hong ve arkadaşları 2011 yılındaki çalışmalarında turizm taleplerini tahmin etmek için destek vektör regresyon tabanlı bir kaotik genetik algoritma kullanmışlardır. Kaotik optimizasyon ve genetik algoritma destek vektör regresyonun üç parametresini düzenleyerek yerel optimumlardan kaçmasını sağlamaktadır. Yazarlar, turizm talebini tahmin etmede önerdikleri yöntemin yazındaki diğer yöntemlerden daha iyi olduğunu raporlamışlardır (Hong vd., 2011).

Altuntaş ve Selim 2012’deki makalelerinde, farklı ağırlıklı birliktelik kural tabanlı veri madenciliği yöntemlerini tesis yerleşim problemlerine uygulamışlardır. Yazarlar, yaklaşımları simülasyon kullanarak tesis yerleşim problemleri için genel performans kriterleri açısından karşılaştırmışlardır (Altuntaş ve Selim, 2012).

2.2.3. Kamu Alanında Uygulamalar

Kamu alanında kurum kaynaklarının doğru kullanılması, kamu kurumlarının kümelenmesi, kamu kurumlarında hile denetimi, kamu güvenliğinin sağlanması, güvenlik problemlerinin önceden tahmin edilmesinde veri madenciliğinden yararlanılmaktadır.

Özcan 2014’de tamamladığı yüksek lisans tezinde sağlık sigortası sahtekârlıklarının veri madenciliği yöntemleriyle tespit edilebildiğini göstermiştir (Özcan, 2014).

Çınaroğlu 2015'deki makalesinde beklenti maksimizasyonu yöntemi ve k-medoid kümeleme algoritması ile kamu hastanelerini itibar ve imaj algısı bakımından 6 kümeye ayırmıştır (Çınarlıoğlu, 2015).

Kalkınma Bakanlığı'na göre vergi kaçaklarının önlenmesi için yapılan vergi beyanları incelemesi ve yanlış/hatalı beyanların belirlenmesi, internet üzerinden toplanan veriler ve kamudaki diğer verilerin entegrasyonu sonucunda bilgi güvenliği risklerinin daha iyi bir şekilde analiz edilmesi ve güvenlik kameraları, kişisel konum bilgisi sağlayan cep telefonu, sensor gibi araçlarla toplanan verilere dayalı güvenlik uygulamalarının geliştirilmesi gibi çok farklı konularda büyük veri toplanabilir ve veri madenciliği uygulamaları kullanılarak tahminler yapılabilir (Kalkınma Bakanlığı, 2015: 132).

Kamu kurumları vatandaşın ihtiyaçlarını ve davranışlarını anlama, olayları önceden tahmin etme, bütçelerini ve mevcut insan kaynaklarını en optimum şekilde kullanma amacıyla veri madenciliği süreçlerini uygulayabilirler.

2.2.4. Ticaret ve Pazarlama Alanında Uygulamalar

Veri madenciliği algoritmaları pazarlama ve perakendecilikte yoğun bir şekilde kullanılır. En yoğun kullanım alanları; müşteri segmentasyonu, kitlesel bireyselleştirme, müşteri davranış tahmini, müşteri ilişkileri yönetimi, müşteri hizmetleri desteği, ürün karmasının belirlenmesi, pazar sepet analizi, tüketici tercihlerinin belirlenmesi, tüketici satın alma karar sürecine etki eden faktörlerin tespiti, satış tahmini, kayıp müşteri analizi ve müşteri sadakat analizidir.

Mehmet Aydın Ulaş tarafından 2001 yılında yapılan bir yüksek lisans çalışmasında, sepet analizi gerçekleştirilmiştir. Büyük süpermarket zinciri olan Gima Türk A.Ş.'nin verileri üzerine Apriori algoritması uygulanmış ve ortaya çıkan sonuçlar incelenmiştir. Ayrıca mal satışları arasındaki ilişkileri bulmak amacıyla da, temel bileşenler analizi ve k-ortalama kümelemesi metotları kullanılmıştır (Ulaş, 2001).

Kalikov tarafından 2006'da yapılan çalışmada, bir yayınevi firmasının internet sitesindeki veriler dikkate alınarak, veri madenciliği birliktelik kuralları tekniği ile sepet ve sipariş tabloları incelenmiştir. Hangi ürünlerin kategorisinin değiştirilmesi gerektiği, kullanıcıların meslek ve ilgi alanı dağılımları, müşteri ilgi alanlarına göre satış grafikleri ve kullanıcıların ödeme seçenekleri ile ilgili bir veri madenciliği uygulaması gerçekleştirilmiştir (Kalikov, 2006).

Akbulut tarafından 2006'da yapılan çalışma, bir kozmetik markasının müşteri gruplarını ve ayrılma eğilimi gösteren müşteri kesitini belirleyerek; bu müşterilere özel pazarlama stratejileri geliştirilmesini hedeflemektedir. Bölümlenme için kümeleme teknikleri, ayrılacak müşteri kesitini belirlemek için sınıflama teknikleri kullanılmıştır (Akbulut, 2006).

Savaşçı ve Tatlıdil tarafından 2006 yılında müşteri ilişkileri yönetimi üzerine bir çalışma gerçekleştirilmiştir. Bu çalışmada bireysel bankacılık alanında uygulanan müşteri ilişkileri yönetim süreci incelenmiş ve müşteri sadakatini artırılmasını sağlayan kredi kartlarında uygulanan Müşteri İlişkileri Yönetimi (Customer Relations Management - CRM) stratejileri değerlendirilmiştir (Savaşçı ve Tatlıdil, 2006: 12).

Özçakır ve Çamurcu tarafından 2007'de gerçekleştirilen bir çalışmada, bir firmanın pastane satış verileri üzerinde veri madenciliği uygulamak için birliktelik kuralları ile bir yazılım tasarlanmıştır. Genelde aynı ürün grubuna ait ürünlerin, en sık birlikte satın alınan ürünler olduğu görülmüştür (Özçakır ve Çamurcu, 2007).

Güntürkün 2007 yılında işletmelerin kalite iyileştirmelerini araştıran bir yüksek lisans tezi hazırlamıştır. Ayrıca bu çalışmada, sürücü koltuğu kalitesi için müşteri memnuniyeti verisi analiz edilmiştir. Müşterinin sürücü koltuğundan memnuniyetini etkileyen en önemli değişkenlerin belirlenmesi için karar ağaçları yaklaşımı uygulanmıştır. Bu uygulamadan elde edilen sonuçlar diğer bir çalışmada aynı veri kümesine uygulanmış ve lojistik regresyon analizinden elde edilen sonuçlarla karşılaştırılmıştır (Güntürkün, 2007).

Bashar 2007'deki makalesinde, bir yandan müşteri memnuniyetini en üst seviyeye çıkartacak bileşenleri sıralarken diğer yandan işlemleri ve maliyetleri azaltan turizm paketleri oluşturmak için veri madenciliği tabanlı bir kitlesel bireyselleştirme modeli geliştirmiştir. Yazar, büyük seyahat acentalarının veri tabanlarındaki gizli ilişkileri keşfederek, seyahat paketlerini müşteri ihtiyaçlarına göre özelleştirmek için birliktelik kuralları tekniğini kullanmıştır. Yazar, birliktelik kuralları yardımıyla oluşturulan seyahat paketleri için maliyet minimizasyonu problemini tamsayılı programlama yöntemi ve sezgisel bir yöntemle çözmüştür. Yazar sezgisel yöntemin ele alınan problem için tamsayılı programlama ile aynı sonucu verdiğini raporlamıştır (Bashar, 2007).

Liao ve arkadaşları 2008'de yayınlanan makalelerinde Carrefour'un Tayvan şubesindeki ürün karmasını oluşturmak için Apriori birliktelik kuralı ve K-ortalamalar algoritmasını kullanmıştır. Bu algoritmalar yardımıyla çıkarılan bilgi ile ürün hattı,

marka uzantıları ve bilgi yönetimi için öneri ve çözümler sağlayacak bilgi kalıpları, kurallar ve kümeler oluşturmıştır (Liao vd., 2008).

Gürbüz ve arkadaşları tarafından 2009'da gerçekleştirilen başka bir çalışmada, Türkiye'de bir hava yolu işletmesinin parça söküm raporları üzerinde veri madenciliği çalışması gerçekleştirilmiştir. Çalışmanın amacı, uçaklarda kullanılan parçaların, herhangi bir arıza oluşmadan önce düzeltici ve önleyici işlemlerin yapılması için ikaz seviyelerinin tespit edilmesine yönelik kural geliştirmektir. Sonuç olarak parçaların ikaz seviyelerini temsil edecek anlamlı kurallar elde edilmiş ve bulunan kurallar doğrulukları ve güvenilirlikleri bakımından test edilmiştir (Gürbüz vd., 2009).

Ngai ve arkadaşları 2009 yılında 2000-2006 yılları arasında müşteri ilişkileri yönetiminde veri madenciliği uygulamalarını derlediği bir makale yayınlamıştır. Bu çalışmada yazarlar, çalışmalarını 4 CRM alanında ele almışlardır: müşteri tanıma, müşteri cazibesi, müşteri tutma ve müşteri geliştirme. Yazarlar, veri madenciliği yöntemlerine göre de çalışmalarını 7 bölümde ele almışlardır: birliktelik kuralları, sınıflandırma, kümeleme, tahmin, regresyon, dizi keşfi ve görselleştirme. Yazarlar araştırmacıların en çok müşteri tutma alanında çalışma yaptıklarını ve bunların çoğunun ise, birebir pazarlama ve sadakat programlarına ilişkin çalışmalar olduğunu tespit etmişlerdir. Veri madenciliği yöntemi olarak en fazla sınıflandırma ve birliktelik kurallarının kullanıldığı yazarlar tarafından bildirilmiştir (Ngai, Xiu ve Chau, 2009).

Liu ve Chen, 2009 yılındaki makalelerinde sağlık bakım pazarını hasta tercihleri yönünden segmentasyona tabi tutmuşlardır. Yazarlar, çalışmada hiyerarşik kümeleme algoritmasını ve korelasyon prosedürünü uygulamışlardır. Sonuçların geleneksel segmentasyon yöntemlerinden daha etkili olduğu yazarlar tarafından tespit edilmiştir (Liu ve Chen, 2009).

Yılmaz 2009'da tamamladığı yüksek lisans tezinde, on iki farklı şirketin 2007-2008 yılı cirolarını inceleyerek bir sonraki dönemde firma ile ilişkisini sürdürecektir müşterileri tahmin etmeye çalışmıştır. Tahmin sürecinde çeşitli modeller deneyerek en iyi sonucu veren lojistik regresyon modeli kullanılmıştır. Yazar, bir sonraki dönemde firma ile ilişkisinin devam edeceği bulunan müşteriler için yaşam boyu müşteri değerini hesaplamıştır (Yılmaz, 2009).

Taşkın ve Emel tarafından 2010 yılında veri madenciliğinde kümeleme yaklaşımları ve Kohonen ağları ile perakendecilik sektöründe bir uygulama gerçekleştirilmiştir. Bu uygulamada; bir perakende işletmenin müşterilerinin Kohonen ağları ile kümelenebileceği ele alınmıştır. Kümeleme analizinin amacı; ele alınan

iřletmeye, pazar bölümlendirmesi ve hedef pazar seçimi gibi stratejik pazarlama kararlarında yardımcı olması için önceden bilinmeyen kritik müşteri özellikleri ve önem derecelerini de ortaya çıkararak gerekli öngörüyü sağlamaktır (Tařkın ve Emel, 2010).

Gürsoy, 2010'da yayınlanan makalesinde telekomünikasyon sektöründe kayıp müşteri olma potansiyeli taşıyan müşteri profilini belirlemek için lojistik regresyon ve regresyon karar ağacı sınıflandırma algoritmalarını kullanmıştır. Yazarın ifadelerine göre logistik regresyon analizinde kayıp olmayan müşterileri doğru sınıflama yüzdesi % 74,3 iken kayıp müşterileri tahminleme doğruluęu % 66'dır. Regresyon karar ağacının doğru sınıflama performansı % 71,76 iken yanlış sınıflama oranı % 28,24 olduęu yazar tarafından belirlenmiştir (Gürsoy, 2010).

Rajagopal 2011'deki makalesinde, veri madencilięi teknięiyle yüksek kârlı, yüksek değerli ve düşük riskli müşterileri tanımlamak için kümeleme algoritmaları uygulamıştır. İlk aşamada yazar, verileri temizlemiş ve IBM I-Miner yazılımını kullanarak demografik kümeleme algoritması aracılığıyla modelleri geliřtirmiştir. İkinci aşamada, verileri profillemiş, kümeler geliřtirmiş ve yüksek değerli, düşük riskli müşterileri belirlemiştir. Yazar, Bu kümelerin, genellikle gelirin % 80'ini oluşturan müşterilerin yüzde 10-20'sini temsil ettięini ifade etmiştir (Rajagopal, 2011).

Dura ve arkadaşları 2014'de yayınlanan makalelerinde, bir bankanın doğrudan pazarlama kampanyası verilerini yapay sinir ağları, lojistik regresyon ve karar ağaçları ile analiz etmişlerdir. Çalışma sonucunda yazarlar, yapay sinir ağları yönteminin kampanyaya katılacak müşteri kitlesinin tahmininde, karar ağaçları ve lojistik regresyon modellerine göre daha iyi sonuç verdięini göstermişlerdir. Yazarlar bu modelin, hedef müşteri kitlesinin en doğru şekilde seçilmesinde, kampanyanın başarısını etkileyen temel özelliklerin belirlenmesinde ve kaynakların yönetiminde etkili olarak, kampanyaların etkinlięini arttırabileceęini öne sürmüşlerdir (Akdeniz Dura vd., 2014).

Öztemiz ve Hamamcı, 2016 yılında sunduęu bildirisinde, bir marketin 2014 yılı verilerinde apriori algoritması yardımıyla market sepet analizi yapmışlardır. Yazarlar, güven düzeyi yüksek olan ürün grupları için promosyonlar yapılabileceęi önerisini sunmuşlardır (Öztemiz ve Hamamcı, 2016).

Ceylan ve arkadaşları 2017'de yayınlanan makalelerinde bir bireysel emeklilik řirketinin verilerine iki aşamalı kümeleme analizi uygulayarak müşterileri 3 gruba ayırmışlardır (Ceylan vd., 2017).

2.2.5. Bankacılık, Finans ve Borsa Alanında Uygulamalar

Veri madenciliğinin en yaygın kullanıldığı uygulama alanlarından biride bankacılık, finans ve borsadır. Kredi kartı ve kredi taleplerinin değerlendirilmesinde, risk analizinde, risk yönetiminde, hisse senedi fiyatlarının tahmin edilmesinde, yatırımların modellenmesinde veri madenciliğinden yararlanılmaktadır.

Ata ve arkadaşları tarafından 2007 yılında gerçekleştirilen çalışmada, yaşam çözümlemesi yöntemlerini veri madenciliği konusu çerçevesinde ele aldıktan sonra kredi kartı sahiplerine ait bir veri kümesi için yaşam olasılıkları, hazard olasılıkları ve regresyon modelleri incelenmiştir. Buna göre çalışmada yaş, gelir ve medeni durumun, müşterilerin kredi kartı kullanmayı bırakmalarını etkileyen önemli risk faktörleri olduğu görülmüştür (Ata vd., 2007).

Özbay 2007 yılında tamamladığı yüksek lisans tezinde veri madenciliği ile finans sektöründe dolandırıcılık tespitinin nasıl yapılabileceği konusunda bir örnek uygulama yapmıştır (Özbay, 2007).

Albayrak ve Yılmaz tarafından 2009 yılında gerçekleştirilen bir çalışmada, İMKB 100 endeksinde sanayi ve hizmet sektörlerinde faaliyet gösteren 173 işletmenin 2004–2006 yıllarına ait yıllık finansal göstergelerinden yararlanarak veri madenciliği tekniklerinden birisi olan karar ağaçları tekniği uygulanmıştır. Seçilen finansal göstergelere göre sanayi ve hizmet sektörlerinde faaliyet gösteren firmaları ayıran en önemli değişkenler saptanmıştır. Yazarlar, sanayi ve hizmet sektörlerinde faaliyet gösteren firmaları ayırmada etkili olan değişkenlerin işletme sermayesinin net satışlara oranı, stok devir hızı ve ekonomik rantabilite oranı değişkenleri olduğunu raporlamışlardır. (Albayrak ve Yılmaz, 2009).

Ayrıca Albayrak tarafından gerçekleştirilen başka bir çalışmada (2009), yerli ve yabancı olarak önceden grup üyeliği belirlenmiş bankaların sınıflandırmasında yaygın olarak kullanılan veri madenciliği tekniklerinden, diskriminant, lojistik regresyon ve karar ağacı modelleri karşılaştırılmıştır. Üç sınıflandırma tekniği, bankalarla ilgili seçilmiş likidite, gelir-gider, karlılık ve faaliyet oranları kullanılarak karşılaştırılmaktadır. Araştırmanın sonuçları, bankaların sınıflandırmasında karar ağacı modelinin geleneksel diskriminant ve lojistik regresyon modellerine üstünlük sağlayarak alternatif etkili bir sınıflandırma tekniği olarak kullanılabileceğini göstermiştir (Albayrak, 2009).

Ata ve Seyrek tarafından 2009 yılında gerçekleştirilen bu çalışmada, denetçiler tarafından yaygın olarak bilinmeyen bazı veri madenciliği teknikleri, finansal tablolardaki hileleri tespit etmeye yardımcı olmak üzere kullanılmıştır. Çalışma İMKB’de işlem gören ve imalat sektöründe faaliyet gösteren 100 firmanın bilgilerine dayalı olarak gerçekleştirilmiştir. Araştırma sonucunda kaldıraç oranı ve aktif karlılık oranının finansal tablo hilesini tespit etmede önemli finansal oranlar olduğu belirlenmiştir (Ata ve Seyrek, 2009).

2.2.6. İnternet Alanında Uygulamalar

Bilgisayar teknolojilerinin gelişmesi ve artan internet kullanımına bağlı olarak internet alanında gerçekleştirilen veri madenciliği geniş bir uygulama alanına sahiptir. Kullanıcı profillerinin belirlenmesi, kötü niyetli kullanıcıların tespit edilmesi, web sayfalarının kullanıcı bilgilerine göre kişiselleştirilmesinin sağlanması gibi alanlarda veri madenciliğinden yararlanılmaktadır.

Şeker 2014’de yayınlanan makalesinde sosyal ağlarda veri madenciliği uygulamasının nasıl yapılabileceğini göstermiştir (Şeker, 2014).

Kaşıkcı ve Gökçen 2014’deki makalelerinde kullanıcının belirlediği web sitelerinin e-ticaret sitesi olup olmadığını belirlemek üzere K - en yakın komşu (K Nearest Neighborhood - KNN) ve Navie Bayes sınıflandırıcıları kullanmışlardır. Yazarlar, Navie Bayes sınıflayıcının K - en yakın komşu algoritmasından daha iyi sonuç verdiğini raporlamışlardır (Kaşıkcı ve Gökçen, 2014).

Işık ve Çamurcu 2008’deki makalelerinde web sayfalarını kümeleme analizlerinde Öklid, Kosinüs, Pearson ve Genişletilmiş Jaccard uzaklık veya benzerlik ölçütlerinin etkinliğini araştırmışlardır. Yazarlar en iyi sonucun kosinüs ve genişletilmiş Jaccard benzerlik ölçütleriyle alındığını raporlamışlardır (Işık ve Çamurcu, 2008).

2.2.7. Eğitim Alanında Uygulamalar

Eğitim alanında veri madenciliğinden öğrenci verilerinin analiz edilmesi, öğrenci başarı ve başarısızlık nedenlerinin tespit edilmesi, öğrenci başarılarının artırılması, eğitim-öğretim ortamlarındaki aksaklıkların tespit edilmesi, daha etkili eğitim-öğretim ortamlarının oluşturulmasında yararlanılmaktadır.

Eğitim kurumlarının veri tabanı yönetim sistemlerinde öğrencilere, programlara, öğretim personeline, ders ortamlarına vb. bilgilere ait veriler bulunur. Bu veriler eğitim ve öğretimle ilgili birçok gizli bilgiyi bünyesinde taşıyabilirler. Bu verilere veri madenciliği süreçleri uygulanırsa akademik başarıların artması ve olumsuzlukların giderilmesi mümkün olabilir. Eğitimde veri madenciliğinin uygulandığı çok sayıda çalışma vardır.

Kurt ve Erdem'in 2012 yılındaki makalesinde öğrencilerin akademik başarılarına etki eden faktörlerin belirlenmesi için CRT (Classification and Regression Trees), CHAID (**Chi-Squared Automatic Interaction Detector**), sinir ağları, apriori algoritması, k-ortalamlar kümeleme algoritması denenmiştir. Araştırmada öğrencilerin akademik ortalamalarına mezun oldukları lise mezuniyet notunun etkisi olduğu, mezuniyet sonrası iş bulma olasılığının yüksek olmasının akademik başarıyı olumlu etkilediği, kişilik özelliklerinin akademik başarı üzerinde çok etkili olduğu, birinci öğretim öğrencilerinin ikinci öğretim öğrencilerinden daha başarılı olduğu, araştırmacı kişilik yapısının akademik başarıyı olumlu etkilediği sonuçları raporlanmıştır (Kurt ve Erdem, 2012).

Özby 2015'deki makalesinde eğitim sektöründe veri madenciliğinin kullanımına ilişkin bir yazın özeti sunmuştur. Bu makalede yazındaki çalışmaların: öğrencilerin akademik başarı ve başarısızlıkları ile bunları etkileyen faktörlerin belirlenmesi, öğrencilerin özelliklerine göre gruplara ayrılması, öğrenci mezuniyet notlarının tahmin edilmesi, üstün yetenekli öğrencilerin sıklıkla ilgi duyduğu alanların tespiti, öğrencilerin Öğrenci Seçme ve Yerleştirme Merkezi (ÖSYM) puanları ile akademik başarıları arasındaki ilişkilerin tespiti, akademik başarıya etki eden faktörlerin belirlenmesi amacıyla gerçekleştirildiğini göstermektedir (Özby, 2015).

Çöllüoğlu Gülen ve Özdemir 2013'deki makalelerinde Üstün yetenekli öğrencilerin ilgi alanlarını tahmin etmek için 10 sınıflandırma algoritmasını test etmiştir. Yazarlar, en doğru sınıflama yapan algoritmanın Jrip algoritması olduğunu raporlamıştır. Ayrıca aynı anda farklı alanlardan hangilerine ilgi duyduklarını belirlemek üzere apriori birliktelik kuralları algoritmasını uygulayan yazarlar, mekanikle ilgilenen öğrencilerin fen bilimleri ile, sosyal bilimlerle ilgilenenlerin fen bilimleri ile ve son olarak sanatla ilgilenenlerin yabancı dille ilgilendiklerini tespit etmişlerdir (Çöllüoğlu Gülen ve Özdemir, 2013).

Şengür 2013'de tamamladığı yüksek lisans tezinde yapay sinir ağları ve karar ağaçlarını kullanarak Fırat Üniversitesi, Eğitim Fakültesi, Bilgisayar ve Öğretim

Teknolojileri Eğitimi Bölümü (BÖTE) öğrencilerinin mezuniyet notlarını tahmin etmiştir. Yazar çalışmasında, yapay sinir ağlarının öğrenci mezuniyet notlarını karar ağaçlarından daha iyi tahmin ettiğini raporlamıştır (Şengür, 2013).

2.3. KULLANILAN YÖNTEMLER

Birçok kaynak veri madenciliği teknikleri için kullandıkları veri tiplerine, amaçlarına, öğrenme şekline vb. çeşitli kriterlere göre farklı gruplandırmalar yapmıştır. Bunlardan en yaygın kabul göreni J. Han'ın ortaya sürdüğü kategorilerdir. J. Han kategorilerini kullanan kaynaklar bile, hangi algoritmanın hangi kategoriye ait olduğu konusunda net görüş birliğine sahip değildir. Bu kategoriler aşağıdaki gibidir (Han vd., 2012: 15):

- Karakterizasyon ve Ayırma (Characterization and Discrimination),
- Sık Desen, Birliktelik ve Korelasyon Madenciliği (Mining Frequent Patterns, Associations, and Correlations)
- Tahminleyici Analiz için Sınıflandırma ve Regresyon (Classification and Regression for Predictive Analysis),
- Kümeleme Analizi (Cluster Analysis),
- Sıradışılık (istisna – uç değer) Analizi (Outlier Analysis).

2.3.1. Karakterizasyon ve Ayırma

Veri girişleri sınıflar ve kavramlarla ilişkili olabilir. Elektronik mağazalarında ürünler, bilgisayarlar ve yazıcılar şeklinde, müşteriler ise sınırlı harcama yapanlar ve büyük müşteriler şeklinde sınıflandırılabilir. Bireysel sınıf ve kavramları özetlenmiş, kısa ve yeterince açık olarak tanımlamak yararlı olabilir. Bu tanımlar kullanılarak, (1) veri karakterizasyonu, genel olarak incelenen sınıfın verilerini özetler, (2) veri ayırma, hedef sınıfın bir veya bir dizi ile karşılaştırılması yapılabilir (Han vd., 2012: 15).

Veri karakterizasyonu, bir hedef sınıfın genel karakteristikleri veya özelliklerinin bir özetidir. Kullanıcı tarafından belirtilen sınıfa karşılık gelen veriler tipik olarak bir sorgu tarafından toplanır. Örneğin, önceki yıla göre satışları % 15 artan ürünlerin karakteristiklerini incelemek için, bu tür ürünlere ilişkin veriler, satış veritabanından bir SQL (Structured Query Language) sorgusu yürütülerek toplanabilir. Veri kübü tabanlı OLAP (Online Analytical Processing) biriktirme

işlemleri, belirli bir boyutta kullanıcı kontrollü veri özetleme için kullanılabilir (Han vd., 2012: 16).

Veri ayırma hedef sınıf veri nesnelerinin genel özelliklerinin bir veya bir dizi karşıt sınıfların veri nesneleri özellikleriyle karşılaştırılmasıdır. Hedef ve karşıt sınıflar kullanıcı tarafından belirlenebilir ve ilgili veri nesneleri veritabanı sorguları aracılığıyla elde edilebilir. Örneğin bir kullanıcı, önceki yıla göre satışları % 10 artan ürünlerle satışları en az % 30 azalan ürünleri karşılaştırmak isteyebilir. Veri ayırma için kullanılan yöntemler, veri karakterizasyonu için kullanılanlara benzerdir. Ayırma tanımlamaları, hedef ve zıt sınıflar arasında ayırım yapmaya yardımcı olacak karşılaştırmalı ölçüleri içermelidir. Kurallar şeklinde ifade edilen ayırma tanımlamaları, ayırma kuralları olarak adlandırılır (Hanvd., 2011: 16).

2.3.2. Sık Desen, Birliktelik ve Korelasyon Madenciliği

Sık desenler, verilerde sıkça görülen kalıplardır. Sık kullanılan öge setleri, alt diziler ve alt yapılar gibi çeşitli sık desen modelleri vardır. Sık öge setleri, genellikle bir işlem veri setinde sıklıkla birlikte görülen öge kümesini ifade eder. Sık görülen bir alt dizi, müşterilerin önce bilgisayar, sonra dijital kamera ve daha sonra hafıza kartı alma eğilimleri gibi ardışık modellerdir. Bir alt yapı, öge dizileri veya alt dizilerle birleştirilebilecek farklı yapısal formları (örneğin, grafikler, ağaçlar veya kafesler) gösterir. Sık desen madenciliği, veri içindeki ilginç birliktelik ve ilişkilerin keşfine yol açar.

Birliktelik kuralları (Association Rules), olayların birbirlerine bağlı olarak gerçekleşme durumlarını olasılık terimleriyle ortaya koyar. Bu yöntemin temel amacı, veriler arasındaki ilginç ilişkileri ortaya çıkarmaktır (Alaeddinoğlu vd., 2012).

Birliktelik kuralları, kullanıcı tarafından en küçük değeri belirlenen destek ve güvenilirlik oranını sağlayacak şekilde üretilir. Destek, A ve B olaylarının veri kümesinde beraber bulunma yüzdesidir. Güvenilirlik ise, A ve B olaylarının beraber olma sayısının A olayı bulunan veri sayısına oranıdır. Destek ne kadar yüksekse, kural o kadar sık tekrarlanmaktadır. Güven ne kadar yüksekse kuralın o kadar az istinası var demektir.

Birliktelik kuralına ilişkin olarak geliştirilen bazı algoritmalar şunlardır; AIS - Agrawal, Imelinski, Swami algoritması – AIS (Agrawal vd., 1993), Set-Oriented Mining - SETM (Houtsma ve Swami, 1995), Apriori (Agrawal ve Srikant, 1995),

Partition (Savasere vd., 1995), Rapid Association Rule Mining - RARM (Das vd., 2001), Closed Association Rule Mining - CHARM (Zaki ve Hsiao, 2002). Bu algoritmalar içerisinde, ilk olanı AIS, en yaygın kullanılanı ise Apriori algoritmasıdır.

Birliktelik kurallarında her kural bir destek ve güven değeri ile ifade edilir. Bir birlikteliğin kural sayılabilmesi için destek ve güven için alt sınırlar belirlenmelidir. Bir kuralın destek ve güveni ne kadar yüksekse kural o kadar güçlüdür (Çelik vd., 2017).

Birliktelik kuralları belirlendikten sonra, birliktelik özellik - değer çiftleri arasındaki ilginç istatistiksel korelasyonları ortaya çıkarmak için ek analizler yapılabilir.

2.3.3. Tahminleyici Analizler (Sınıflandırma, Regresyon ve Zaman Serisi Analizleri)

Eldeki verilere göre bazı tahminlerin yapılması gerekebilir. Nitel değişkenlerin tahmininde sınıflandırma algoritmaları kullanılırken, nicel verilerin tahmininde regresyon ve zaman seri analizleri kullanılmaktadır.

2.3.4. Sınıflandırma

Çok değişkenli analizlerde sınıflandırma problemleri önemli bir yere sahiptir. Araştırmacı farklı veri kaynaklarından gelen p sayıdaki özellikten elindeki bireyin veya nesnenin hangi gruptan geldiğini belirlemek isteyebilir. Bu durumda sınıflandırma problemi, birey veya nesnenin p sayıda özelliğini inceleyerek hangi gruptan geldiğine karar verme problemi olarak tanımlanabilir (Burmaoğlu vd., 2009: 24).

Sınıflandırma, en yaygın kullanılan veri madenciliği tekniğidir ve kategorik sonuçları tahmin etmek için kullanılır. Modeli kurmak için önceden belirlenen durumlar ve bu durumlarda değişkenlerin aldığı değerlerin bilinmesi gereklidir. Bu değerlere eğitim verisi denir. Elde edilecek sonuçlar “hizmeti bırakır-hizmeti bırakmaz” şeklinde iki alternatifli olabileceği gibi, “kesin tercih eder-tercih eder-yanıt vermez-tercih etmez-kesinlikle tercih etmez” şeklinde çoklu alternatifli olabilir. Genellikle veriler öğrenme ve test verisi olarak ikiye ayrılır. Öğrenme kümesi ile algoritma eğitilir ve model oluşturulur, test verisi ile model doğrulanır (Argüden ve Erşahin, 2008: 37).

Sınıflandırma olayına örnek vermek gerekirse bankaların kredi başvurularını düşük, orta ve yüksek riskli şeklinde uygun kategoriye ayırması, çalışanların iyi, kötü veya orta performansa sahip olarak ayırması örnek olarak verilebilir.

Sınıflandırmada kullanılan yöntemlerden bazıları: karar ağaçları, Iterative Dichotomiser 3 - ID3, C4.5, C5, KNN, Navie Bayes, CHAID, Supervised Learning In Quest - SLIQ, Scalable Parallelizable Induction Of Decision Trees - SPRINT ve Classification And Regression Trees - CART algoritmaları; yapay sinir ağları, destek vektör makineleri, kendi kendini düzenleyen haritalar; regresyon modelleri ve ayırma analizidir.

Sınıflandırma algoritmalarının performansının değerlendirilmesinde çeşitli ölçütler kullanılır. Bu ölçütlerden en yoğun olarak kullanılanları: doğruluk (accuracy), sınıflama hatası (classification error), kesinlik (precision), duyarlılık (sensitivity), özgünlük (specificity) ve F ölçütleridir (Özkan, 2016: 85-86).

2.3.5. Regresyon Analizi

Kategorik bir değişkeni tahmin ederken sınıflama algoritmaları kullanılırken süreklilik gösteren bir değişkeni tahminlerken regresyon analizi kullanılmaktadır. Örneğin, bir banka için kredi başvurularının güvenli ve riskli olarak ayırmasını yapmak için sınıflama modeli kurulurken, geliri ve mesleği verilen potansiyel müşterilerin harcamalarını tahmin etmek için regresyon modelleri kurulur (Uyumaz, 2017: 9).

Regresyon analizlerinde bağımsız değişkenlerin bağımlı değişken ile ilişkisini matematiksel olarak modelleyen regresyon denklemleri hesaplanır. Söz konusu modelin başka bir veri setine uygulanması halinde bağımsız değişkenlerin değerlerine göre model matematiksel denklemi kullanarak sonuç üretir. Bazı veri setleri doğrusal iken çoğu veri seti doğrusal değildir. Bu nedenle doğrusal regresyon modelinin yanı sıra polinomial regresyon, vektör doğrusal regresyon, Gauss süreci, ilişki vektör makinesi gibi çeşitli modeller kullanılabilmektedir.

2.3.6. Zaman Serisi Analizi

Gözlem sonuçlarının zamana göre sıralanmış şekline zaman serisi adı verilir. Borsada işlem gören hisse senetlerinin seyri, döviz kurlarındaki değişim, Türkiye'nin enerji tüketimi vb. örnek olarak gösterilebilir (Argüden ve Erşahin, 2008: 42).

Zaman serilerini öğelerine ayırma, aralarındaki ilişkiyi tanımlama, kontrol ve tahmin amacı ile incelenmesine zaman serisi analizi denir. Analiz sonucunda geleceği tahminleyen bir matematiksel model ortaya çıkması gerekir. Yani zaman serisi analizi, geçmiş dönem verileri ile geçmişi ve şimdiki durumu açıklayarak gelecek hakkında tahmin üretebilen bir istatistiksel yöntemdir (Çelik, 2008: 94). Bu analiz yönteminin temel varsayımı geçmişteki hareketlerin gelecekte de aynı trendi izleyeceği varsayımıdır.

Zaman serilerinin analizinde kullanılan bir çok yöntem mevcuttur. Bunlardan bazıları; hareketli ortalama yöntemleri, üstel düzeltme, regresyon analizi, Holt-Winters, ARIMA, yöntemleri olarak ifade edilebilir (Özüdoğru ve Görener, 2015: 40).

Zaman serisi analizinde kullanılan boyut indirgeme yöntemleri: Pencereleme (Windowing), Ayırık Fourier dönüşümü (Discrete Fourier Transform - DFT), ayırık dalgacık dönüşümü (Discrete Wavelet Transforms - DWT) ve temel bileşen analizine (Principle Components Analysis - PCA) dayanan tekil değer ayrıştırmasıdır (Singular Value Decomposition - SVD) (Han vd., 2012: 587).

Zaman serisi öngörü modellerinin performanslarının karşılaştırılması amacı ile çeşitli performans ölçütleri kullanılmaktadır. Tahminin performansının testi için, öngörü değerleri ile mevcut olan gerçek değerler arasındaki farklar, yani tahmin hataları (kalıntılar-residuals), bazı formüllerle modellerin tahmin performansını karşılaştırmaya yardımcı olabilecek şekilde standartlaştırılır. Modellerin tahmin performansının değerlendirilmesi için kullanılan ölçütlerden bazıları: Hata Kareleri Ortalaması (Mean Squared Error – MSE), Ortalama Hata Karelerinin Karakökü (Root Mean Squared Error – RMSE), Ortalama Mutlak Hata (Mean Absolute Error – MAE), Ortalama Yüzde Hata (Mean Percentage Error – MPE), Hata Kareleri Toplamı (Sum of Squared Errors – SSE), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error – MAPE) ve Theil-U istatistiğidir (Ataseven, 2013: 113).

2.3.7. Kümeleme Analizi

Kümeleme analizi, olguların, bireylerin veya nesnelerin özelliklerini benzerlik veya farklılıklarına göre gruplara ayırmak için kullanılan çok değişkenli istatistiksel bir tekniktir (Erdoğan ve Esen, 2016: 368).

Kaufman and Rousseeuw (1990)'a göre “kümeleme analizi, bir araştırmada incelenen birimleri aralarındaki benzerliklerine göre belirli gruplar içinde toplayarak

sınıflandırma yapmayı, birimlerin ortak özelliklerini ortaya koymayı ve bu sınıflar ile ilgili genel tanımlar yapmayı sağlar” (Dinler, 2014: 10).

Bir veri setindeki nesnelerin kümelenmesi bu nesnelerin değişken değerlerinden hesaplanan benzerlik veya uzaklıkları kullanılarak gerçekleştirilir. Değişkenlerin kesikli veya sürekli olmalarına veya nominal, ordinal, sıralı, aralıklı ölçekte olmalarına göre doğru benzerlik veya uzaklık ölçüleri kullanılmalıdır (Dinler, 2014: 12-13).

Aralık ölçekli değişkenlerde kullanılan uzaklık ve benzerlik ölçüleri: Öklid, Manhattan, Mahalanobis, Minkowski uzaklıkları ve korelasyon benzerliği, kosinüs benzerliği vb.dir. Nominal verilerde kullanılan uzaklık ve benzerlik ölçüleri: Nominal uzaklığı, Dice benzerliği, Jaccard benzerliği vb. Hem nominal hem de aralık ölçekli değişkenlerin kullanılması durumunda karma öklid uzaklıkları kullanılır.

Yazında çeşitli kümeleme algoritmaları mevcuttur. Bu algoritmalar; hiyerarşik veya hiyerarşik olmayan algoritmalar. Hiyerarşik (aşamalı) algoritmalar: Tek bağlantı yöntemi (Single Linkage), tam bağlantı yöntemi (Complete Linkage), ortalama bağlantı yöntemi (Average Linkage), McQuitty bağlantı kümeleme yöntemi (McQuitty Linkage), küresel (Merkezi) bağlantı kümeleme yöntemi (Centroid Linkage), medyan bağlantı kümeleme yöntemi (Median Linkage) ve Ward’ın minimum varyans algoritmalarıdır. Hiyerarşik olmayan yaklaşımlar; bölme (partitioning), yoğunluk-tabanlı (density-based), ızgara tabanlı (grid-based) ve model tabanlı yaklaşımlardır. K- Ortalamalar, Bulanık C-Ortalamalar, K-Modlar ve X-Ortalamalar bölme kümeleme algoritmalarındandır. **Density Based Spatial Clustering of Applications with Noise - DBSCAN**, **Density - Based Clustering - DENCLUE** ve **Ordering Points To Identify the Clustering Structure - OPTICS** algoritmaları yoğunluk temelli yöntemlerdendir. **Statistical Information Grid-based Method - STING**, Dalga kümeleme (Wave Clustering) ve **Clustering In Quest - CLIQUE** ızgara tabanlı yöntemlerdendir. Bunların dışında kendi kendini organize eden ağlar (Self Organizing Map - SOM) ve destek vektör kümeleme (Support Vector Clustering - SVC) algoritmaları model tabanlı yöntemlerdendir (Sarıman, 2011: 194).

Kümeleme algoritmaları ile ortaya çıkan küme yapılarının geçerliliğini test etmek ve doğru küme sayısını bulmak için bazı geçerlilik ölçütleri geliştirilmiştir. Bunlardan yaygın olarak kullanılanları: Dunn indeksi, Davies-Bouldin indeksi, Silhouette indeksi, C indeksi ve Jaccard indeksleridir.

2.3.8. Sıradışılık (istisna – uç değer) Analizi (Outlier Analysis)

Bir veri seti, verilerin genel davranışına veya modeline uymayan nesneler içerebilir. Bu verilere aykırı- uç değer, istisna veya anormal veri adları verilebilir. Birçok veri madenciliği yöntemi, gürültü veya istisna olarak aykırı değerleri ortadan kaldırır. Bununla birlikte, bazı uygulamalarda (örn. Dolandırıcılık tespiti), nadir olaylar, daha düzenli olarak meydana gelenlerden daha ilginç olabilir. Aykırı verilerin analizi, aykırılık analizi veya anormallik madenciliği olarak adlandırılır. (Han vd., 2012: 21).

Aykırı değerler, veriler için bir dağılım veya olasılık modeli üstlenen istatistiksel testler kullanılarak veya başka kümelerden uzaklıkları kullanılarak tespit edilebilir. İstatistiksel veya mesafe ölçütleri kullanmak yerine, yoğunluk tabanlı yöntemler, genel bir istatistiksel dağılım açısından normal görünmesine rağmen yerel bir bölgedeki aykırı değerleri tespit edebilirler (Han vd., 2012: 22).


Uç değer analizi, bir hesap tarafından yapılan normal harcamalara göre beklenmedik yüksek miktarda harcamaları tespit ederek kredi kartlarının hileli kullanımını ortaya çıkarabilir.

2.4. VERİ MADENCİLİĞİ SÜRECİ

Veri tabanlarında bilgi keşfi (VTBK) veya veri madenciliği, veri tabanlarında saklanan büyük miktarlardaki verilerdeki faydalı bilgilerin keşfini ifade eder. Veri madenciliği, verilerin genel olarak tanımlanmasını sağlayan belirli kümeler veya kuralların, olağan dışı veya sıklıkla meydana gelen desenlerini veya alt gruplarını belirlemeye çabalayan bir süreçtir (Hoche vd., 2006: 188).

Veri madenciliği süreci Şekil 7’de gösterildiği gibi etkileşimli ve tekrarlanan bir süreçtir. Süreç, kullanıcı ile sistem arasında işbirliği gerektiren birçok adımı kapsar ve yeterli sonuçlar alınana kadar bu adımlar pek çok kez tekrarlanabilir (Hoche vd., 2006: 189).

Şekil 7: Veri Tabanından Bilgi Keşfi Süreci (VBTK)



Kaynak: Hoche vd., 2006: 189.

Araştırma adımı, problemin ve amacın ne olduğu tam olarak tanımlanmalıdır. Örneğin araştırma tüketici davranışlarındaki değişimler veya tüketicilerin yaşam tarzlarına göre segmentasyonunu amaçlayabilir. Seçim aşaması, yapılacak analiz için gerekli verilerin farklı kaynaklardan toplanarak birleştirilmesi veya ayrıştırılması, gürültü, uç değer ve kayıp verilere yönelik ön işlemleri kapsar. Çevrim aşamasında veri setindeki kayıtlar veya özellikler gerekirse azaltılabilir. Temel bileşenler analizi bu amaçla kullanılabilir. Veri madenciliği aşamasında çeşitli algoritmalar kullanılarak sınıflandırma, kümeleme, kural çıkarma, birliktelik kuralları çıkarma gibi uygulamalar yapılır. Yorumlama/Hesaplama aşamasında veri madenciliği sürecinde ortaya çıkan desenlerin değerlendirilmesi ve yorumlanması gerekir. Bu aşamadan önceki adımlar istenen amaçlara ulaşana kadar tekrarlanabilir (Hoche vd., 2006: 189-190).

2.4.1. Veri Ön-İşleme

Veri ön-işleme veri madenciliği sürecinin ilk ve en önemli aşamasıdır. Bu aşamada yapılacak bir hata sonraki süreci tamamen etkileyecektir. Bu nedenle verilere ihtiyaç duyulacak bütün ön işlemlerin yapılması gerekir.

2.4.2. Veri Toplama (Data Aggregation)

Bu aşamada farklı veritabanlarında bulunan verilerin veri ambarlarında birleştirilmesi gerekir. Bu aşamada dikkat edilmesi gereken bir husus farklı

kaynaklardan toplanan verilerin birbirleriyle uyumlu olmalarıdır (Vatansever, 2008: 20). Eğer veri madenciliği süreci için bir veri ambarı oluşturulmadıysa veri seti üzerinde veri toplama işlemi uygulanmalıdır (Özkan, 2016: 28).

2.4.2.1. Veri Temizleme (Data Cleaning)

Veritabanlarında yer alan tutarsız veya eksik bilgilere gürültü denir. Verileri bu gürültüden arındırmak için; eksik değer içeren kayıtların atılması, kayıp değerlerin yerine sabit bir değer atanması, diğer verilerin istatistiklerinin (ortalama, maksimum, minimum vb.) atanması veya verilere uygun olan bir tahmin yöntemi (Karar ağacı, regresyon vb.) ile hesaplanan değerlerin atanması yöntemleri uygulanabilir (Coşlu, 2013: 573-574). Ayrıca verilerin uç (aşırı) değerlerden arındırılması da elde edilen sonuçların sağlıklı olmasını sağlar.

2.4.2.2. Veri Dönüştürme (Data Transformation)

Verilerin analize uygun hale getirilmesi için verilere düzleştirme, özetleme, ayırıklaştırma ve normalizasyon gibi ön-işlemler uygulanabilir.

Düzleştirme

Aşırı değerleri gidermek için kümeleme ve regresyon gibi yöntemler kullanılır.

Özetleme

Veriyi özetlemek için kullanılır.

Ayırıklaştırma

Yaş, gelir durumu gibi sınıflanabilecek sürekli verileri nitel değişkene dönüştürmek için kullanılır.

Normalizasyon

Modelde kullanılan değişkenlerin bazılarında ortalama ve varyansın yüksek olması, bu değişkenin diğer değişkenlerden daha baskın olmasına neden olur. Bu durum yapılan sınıflama veya segmentasyon işlemlerinde hata yapılmasına neden olur. Bu hatayı önlemek için normalizasyon yapılmalıdır (Coşlu, 2013: 574) .

Z Skoru Normalizasyonu

Bu yöntemde veriler ortalamalardan çıkartılarak standart sapmaya bölünür ve Z skoru hesaplanır. Bu şekilde verilerin dağılımı ortalaması 0 standart sapması 1 olan normal dağılıma dönüştürülür. Bu nedenle Z skorları negatif veya pozitif olabilirler.

$$Z = \frac{x - \bar{x}}{s} \quad x: \text{Veri}, \bar{x}: \text{Verilerin ortalaması}, s: \text{Verilerin standart sapması}.$$

-1 ≤ x ≤ 1 Aralığına İndirgeme

Eğer veri seti çok heterojen ve uç değerler mevcutsa bu yöntem tercih edilir. Değişkenlerin pozitif veya negatif değerler alması ve |Minimum| ≤ Maksimum olması halinde uygulanır. Dönüşüm aşağıdaki formüle göre yapılır.

$$x'_i = \frac{x_i}{\text{Maksimum}}$$

0 ≤ x ≤ 1 Aralığına İndirgeme (Min Maks Normalizasyonu)

Veri seti heterojen ve uç değerler varsa değişkenlerin 0-1 aralığında ölçeklenmesi mümkündür. Dönüşüm aşağıdaki formüle göre yapılır.

$$x'_i = \frac{x_i - \text{Minimum}}{\text{Maksimum} - \text{Minimum}}$$

Oran Dönüşümü

Veriler tüm verilerin toplamına bölünerek bu dönüşüm sağlanır. Bu toplam pozitif ve negatif sonlu sayılarda kullanılabilir.

$$x'_i = \frac{x_i}{\sum x_i}$$

Çeyrekler Arası Aralık Dönüşümü

Bu yöntemde alt ve üst çeyrek olarak bilinen 25. ve 75. Çeyrekler(Q1 ve Q3) arasındaki mesafe kullanılmaktadır. Dönüşüm aşağıdaki formüle göre yapılır. IQR verilerin orta kısmındaki aralıktır, bu nedenle çeyrekler arası aralık dönüşümü uç değerlerden daha az etkilenir.

$$x'_i = \frac{\text{Medyan}}{\text{IQR}} = \frac{\text{Medyan}}{Q3 - Q1}$$

2.4.2.3. Veri İndirgeme (Data Reduction)

Bir veri madenciliği çalışmasında karar değişkenlerinin sayısı çok fazla ise algoritmaların uygulamasında uzun bir zaman ve daha fazla hafıza gerekli olmaktadır. Bu nedenle çeşitli yöntemlerle boyut indirgeme yapılır. Boyut indirgeme yöntemlerinden bazıları: veri birleştirme veya veri küpü (data Aggregation), boyut azaltma (dimension reduction), veri sıkıştırma (data compression), kesikli hale getirme (Discretization), örnekleme (sampling) dir (Vatansever, 2008: 23).

2.4.2.4. Veri Azaltma

2000-2016 yılları için çeyrek dönemlik satış verilerinden oluşan bir veri seti olduğunu düşünelim. Her yılın dört çeyrek verilerini toplayarak yıllık satışları içeren bir tablo oluşturulduğunda veri setinin hacmi azalır fakat bilgi kaybı olmaz. Bu işleme veri azaltma denir (Vatansever, 2008: 23-24).


2.4.2.5. Veri Küpleri (Data Cube)

KÜP (CUBE) 1997’de Gray ve arkadaşları tarafından Yapısal Sorgulama Dili (Structured Query Language - SQL)’nin gruptama (Group By) işlemcisinin geliştirilmesiyle ortaya çıkarılmıştır.

Veri küpleri çok değişkenli ve çok boyutlu bilginin saklandığı yapılardır. Veri küpleri sayesinde analizler verinin tamamı üzerinde değil sadece belirlenen küçük bir kısmında yapılır. Veri küpleri özet bilgiye herhangi bir hesaplama yapmadan hızlı bir şekilde erişilmesini sağlar (Vatansever, 2008: 24).

Küpler OLAP veritabanlarında kullanılan mantıksal tablolardır. Boyutlarla ölçüm değerlerinin bir arada tutulmasını sağlarlar. Küpler, içine birçok boyutu alarak n-boyutlu ızgaralar oluşturur. Şekil 7’de tipik bir küp örneği görülmektedir (İşli, 2009: 21-22).

Şekil 8: Veri Küplerine Bir Örnek



Kaynak: (İşli, 2009: 22)

Şekil 8'deki örnekte hizmet boyutları, bölüm boyutu ve zaman boyutunun kesiştiği noktada toplam hizmet miktarı ve tutarı verisine ulaşılmaktadır.

Veri küpleri olaylar, boyutlar ve ölçüm değerlerinden oluşmaktadır. Küpün oluşturulduğu ana tabloya olay tablosu denir. Olay tablosu boyut tablolarıyla ilişkilidir. Bir stok kontrol veya satış otomasyonunda olay tablo stok veya satış hareketlerini tutar. Boyut tabloları ise ürünlere, müşterilere ait bilgileri içerir. Boyut tabloları olay tablosuna yabancı anahtar (foreign key) ile ilişkilendirilir.

2.4.2.6. Boyut İndirgeme

İncelenen veri setinde bazen çok sayıda gereksiz değişkenler yer alabilir. Bu tür gereksiz değişkenler hem örüntülerin kalitesini bozar hem de algoritmaların uzun sürmesine neden olurlar. Bu çok sayıdaki değişkeni az sayıda değişkenlere dönüştürmek için temel bileşenler analizi, bağımsız bileşenler analizi (principal component analysis), genelleştirilmiş Hebb algoritması (generalized Hebbian algorithm), tekil değer ayrıştırma analizi (singular value decomposition) ve kendi kendine organize olan ağlar (self-organizing map) gibi yöntemler kullanılmaktadır.

2.4.2.7. Kesikli Hale Getirme

Bazı veri madenciliği uygulamaları sadece kategorik nitelikteki verilere uygulanabilir. Böyle bir algoritmayı çalıştırmadan önce sürekli verilerin kesikli değerlere dönüştürülmesi gerekir. Sürekli veriler kesikli değer aralıklarına

dönüştürülen kategorik verilere söz konusu algoritma uygulanabilecektir. Örneğin yaş değişkeni 1-15, 16-40, 40+ olacak şekilde üç boyuta indirgenerek kesikli hale getirilebilir. Bu işlemde detay bilgiler kaybolursa da genelleştirilmiş veriler daha anlamlı ve yorumlanabilir olacaktır. Aynı zamanda bu indirgeme ile elde edilen verilerin hacmi de azalacaktır (Vatansever, 2008: 25).

2.4.2.8. Örnekleme

Örnekleme ile büyük bir veri setinden o seti temsil edebilecek daha küçük bir veri grubu seçilir. Örnekleme ile elde edilen veriler daha az olduğundan algoritmalarından daha çabuk sonuç almak mümkün olur (Tosun, 2006: 8). Örnekleme yöntemlerinden bazıları: basit rastgele örnekleme, tabakalı örnekleme, önyüklemeli örneklemedir.

2.4.3. Modelleme (Algoritmanın Uygulanması)

Modelleme aşamasında hangi amaç için bir algoritma seçilmesi gerektiğine karar verilmelidir. Sınıflama, bölümlendirme, örüntü tanıma ve birliktelik kuralları için çok sayıda farklı algoritma mevcuttur.

Amaca uygun olan modeli buluncaya dek çok sayıda deneme yapılmalıdır. Çünkü veri madenciliği algoritmaları her veri setinde aynı başarıyı gösteremezler. Bir veri setinde K-ortalamlar daha başarılı iken bir diğerinde k-medoids daha başarılı olabilir. Ortaya çıkan alternatif modeller Silhouette, Davies Bouldin, sınıflama hatası (Classification Error – CE), ortalama mutlak hata- MAE, hata kareleri ortalaması-MSE vb. başarı ölçütlerine göre değerlendirilmeli ve en uygun model seçilmelidir (Yılmaz, 2009: 9).

2.4.4. Sonuçların İncelenmesi

Seçilen algoritmanın verilere uygulanması sonucunda ortaya çıkan sonuçların görselleştirilmesi, geçerliliklerinin incelenmesi ve sonuçların ne anlama geldiği incelenmeli ve anlaşılmalıdır. Kullandığımız yöntem ve elde ettiğimiz sonuçlara göre ya A ürünü ile B ürününün beraber daha çok satılabileceği, ya elimizdeki verilerin üç kümeye ayrıldığı, ya da A ürününün 1. Sınıfta, B ve C ürününün 2. sınıfta yer aldığını söylemek mümkün olabilir.

ÜÇÜNCÜ BÖLÜM

ARAŞTIRMADA KULLANILAN ALGORİTMALAR

Çalışmanın bu bölümünde uygulama bölümünde geliştirilen yazılımda kullanılan algoritmalar kısaca tanıtılmış ve literatür özeti sunulmuştur. İlk olarak akıllı kart verilerini kullanarak başlangıç – varış matrislerini oluşturan algoritmalar incelenmiştir. İkinci olarak yapay sinir ağları incelenmiştir. Üçüncü olarak hedef programlama tanıtılmıştır. Dördüncü olarak genetik algoritmalar ve son olarak sayısal optimizasyon için geliştirilmiş basit bir algoritma açıklanmış ve örnek bir uygulama gösterilmiştir.

3.1. AKILLI KART VERİLERİNDEN DURAK BAZINDA BAŞLANGIÇ-VARIŞ MATRİSİNİN HESAPLANMASINA İLİŞKİN ALGORİTMALAR

Literatürde 2002 yılından bu yana akıllı kart verilerinden başlangıç-varış matrislerinin hesaplanması için benzer algoritmalar geliştirilmiş ve uygulanmıştır. Bu uygulamalardan bazıları Tablo 2’de gösterilmiştir.

Tablo 2: Akıllı Kart Verilerinden Başlangıç-Varış Matrislerinin Hesaplanmasına İlişkin Literatür Araştırması

Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
Barry ve arkadaşları	2002	Origin and Destination Estimation in New York City with Automated Fare System Data	Makale	İstasyondan istasyona BV matrislerini tahmin etmek için New York Metrocard verilerini kullanmışlardır.
Lianfu ve arkadaşları	2007	Study on the Method of Constructing Bus Stops OD Matrix Based on IC Card Data	Bildiri	Changchun, Çin'den gelen verileri kullanarak, otobüs durağı seviyesinde bir BV matrisi oluşturan sayısal bir yöntem sunmuşlardır.
Zhao ve arkadaşları	2007	Estimating a Rail Passenger Trip Origin-Destination Matrix Using Automatic Data Collection Systems	Makale	Bir otomatik araç konumlandırma sistemi sayesinde otobüslerin konumunun bilindiği bir kalkış temelli otomatik ücret toplama sisteminden demiryolu yolculukları için BV matrislerini çıkarmışlardır.

Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
Trépanier ve arkadaşları	2007	Individual Trip Destination Estimation in a Transit Smart Card Automated Fare Collection System	Makale	Kanada Gatinueau'nun verilerinde biniş duraklarından varış noktası tahmin yöntemine odaklanmış ve uygulamışlardır.
Farzin	2008	Constructing an Automated Bus Origin–Destination Matrix Using Farecard and Global Positioning System Data in São Paulo, Brazil	Makale	Yaklaşık 10 yıl önce yapılan bir BV anketinden elde edilen sonuçlarla akıllı kart verilerinin yaklaşık % 5'inden (birçok otobüste GPS ekipmanı bulunmadığından) elde edilen bir başlangıç-varış (BV) matrisinin sonuçlarını karşılaştırmıştır.
Barry ve arkadaşları	2009	Use of Entry-Only Automatic Fare Collection Data to Estimate Linked Transit Trips in New York City	Makale	Akıllı istasyon verileri, metro verileri ve otobüs yolculuğu kontrol verilerini karşılaştırarak akıllı kart verilerinden hesaplanan BV matrisleri doğrulamayı önermişlerdir.
Munizaga ve arkadaşları	2010	Public Transport OD Matrix Estimation From Smart Card Payment System Data	Bildiri	Akıllı kart ve GPS verilerindeki binişlerden inişleri tahmin eden Trépanier ve arkadaşlarının algoritmasında yürüyüş mesafesine ilave olarak genelleştirilmiş zaman mesafesi ölçütünü kullanarak iniş duraklarını tahmin etmiştir. Algoritma ile iniş duraklarının % 82'si tahmin edilebilmiştir.
Wang ve arkadaşları	2011	Bus Passenger Origin-Destination Estimation and Related Analyses Using Automated Data Collection Systems	Makale	Londra'daki Oyster kart verileri için bir BV matrisi tahmin uygulaması geliştirmişlerdir.
Munizaga ve Palma	2012	Estimation of a Disaggregate Multimodal Public Transport Origin–Destination Matrix from Passive Smartcard Data From Santiago, Chile	Makale	Transantiago'nun (Şili) geniş ve karmaşık ağına uyum sağlamak için önceki yöntemlerde değişiklikler önermişlerdir.

Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
Devillaine ve arkadaşları	2012	Detection of Activities of Public Transport Users by Analyzing Smart Card Data	Makale	Yazarlar Santiago Şili ve Gatineau, Kanada akıllı kart ve GPS verilerine göre kullanıcıların davranışlarını ve aktivitelere katılımlarını incelemişlerdir. İnişten sonraki 30 dakikada bir binış olmazsa yazarlar bunu bir aktivite olarak görmektedirler.
Nasiboğlu ve arkadaşları	2012	Origin-Destination Matrix Generation Using Smart Card Data: Case Study for Izmir	Bildiri	Yazarlar İzmir akıllı kart verilerini kullanarak 12 bölge için BV matrisini oluşturmuş ve istatistiksel bir analiz sunmuşlardır.
Devillaine ve arkadaşları	2013	Towards a Reliable Origin-Destination Matrix from Massive Amounts of Smartcard and GPS Data: Application to Santiago	Makale	Akıllı kart verilerinden elde edilen bir BV matrisinin potansiyel yanlışlığını analiz etmiş ve bu odak ile, mevcut verilerin analizini yaparak, endojen doğrulama imkanını araştırmışlardır. Yazarlar sonuçlarını ekzojen verilerle doğrulamaya çalışmışlar, ancak kullandıkları anketin, mevcut akıllı kart verisinden farklı bir haftaya denk geldiğini raporlamışlardır.
Jun ve Dongyuan	2013	Estimating Smart Card Commuters Origin-Destination Distribution Based on APTS Data	Makale	Yazarlar verilerin mekansal-zamansal analizi ile ev ve iş yerlerini tanımlayan bir tahmin algoritması geliştirdi. Bu algoritma yolculuk zincirleme algoritması ile karşılaştırılarak analiz edilmiştir. Yazarlar önerilen yöntemin hızlı ve yüksek doğruluğa sahip olduğunu raporlamışlardır.

Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
Munizaga ve arkadaşları	2014	Validating Travel Behavior Estimated from Smartcard Data	Makale	Akıllı kart ve GPS verileri ile elde edilen başlangıç-varış matrislerinin geçerliliğini doğrulamak için akıllı kart veritabanı, kullanıcılara uygulanan BV matris anketi sonuçları ve kişisel bilgilerini paylaşan bir örneklemden elde edilen verilerle endojen ve ekzojen doğrulama yapmış ve % 90 doğruluk oranı tespit etmişlerdir.
Eldemir ve arkadaşları	2015	Istanbul's BRT Trip Destination Estimation and Validation	Bildiri	Yazarlar İstanbul BRT sisteminin uzaklığa dayalı ödeme verilerinden faydalanarak BV matrisi doğrulamışlardır. Bu çalışmada akıllı kart verilerinden elde edilen BV matrislerin % 95'inin doğruluğu kanıtlanmışlardır.
Widyawan ve arkadaşları	2017	Big Data Analytic for Estimation of Origin-Destination Matrix in Bus Rapid Transit System	Bildiri	Yazarlar Jakarta Otobüs şirketindeki akıllı kart verilerini kullanarak BV matrisi yolculuk zincirleme yöntemi ile tahmin edilmiştir.
Hora ve arkadaşları	2017	Estimation of Origin-Destination matrices under Automatic Fare Collection: the Case Study of Porto Transportation System	Bildiri	Yazarlar literatürde yolculuk zincirleme adıyla bilinen yöntemi kullanarak Porto şehri için Ocak 2013 verileriyle durak bazında BV matrisi oluşturmuşlardır.
Amaya ve arkadaşları	2018	Estimating the Residence Zone of Frequent Public Transport Users to Make Travel Pattern and Time Use Analysis	Makale	Yazarlar toplu taşımayı sık kullananların ikamet bölgesini tahmin etmek amacıyla bir algoritma önermişlerdir. Yazarlar, algoritma sonuçlarının ekzojen verilerle % 70 oranında doğrulandığını raporlamışlardır.

Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
Espinoza ve arkadaşları	2018	Assessing the Public Transport Travel Behavior Consistency from Smart Card Data	Makale	Yazarlar toplu taşıma seyahat davranışlarının tutarlılığını ölçmek için üç algoritmayı değerlendirmişlerdir. Yazarlar, seyahat davranışlarındaki değişime TPM algoritmasının çok duyarlı, EDM algoritmasının az duyarlı olduğunu ve Rols-FV algoritmasının çok düzenli yolcuları diğerlerinden ayırmada faydalı olduğunu raporlamışlardır.

Tablo 2’den görülebileceği gibi BV matrisi hesaplamak için geliştirilen algoritmaların ortak özelliği ilk olarak biniş duraklarından iniş duraklarını belirlemeye yönelik algoritmaların oluşturulmasıdır. İniş durakları belirlendikten sonra BV matrislerin hesaplanması, yük profillerinin oluşturulması, maksimum talep düzeylerinin hesaplanması mümkün olmaktadır.

Biniş duraklarından iniş duraklarının tahmin edilmesinde kullanılan temel yaklaşım Trépanier ve arkadaşları (2007) tarafından geliştirilen yolculuk zincirleme yaklaşımıdır. Bu yaklaşım iki temel varsayıma dayanır: (1) Aktarma olduğu tespit edilirse (90 dakikada ikinci biniş) ilk binişin yapıldığı hattaki duraklardan ikinci biniş noktasında en yakın durak eğer yürüme mesafesindeyse iniş durağıdır, (2) yolcular akşam son inişlerinde sabah ilk biniş yaptıkları durağa yakın bir durağı tercih ederler (muhtemelen evleri bu durağa yakın olduğu için). Trépanier ve arkadaşları (2007) maksimum yürüme mesafesini 2 km olarak belirlerken, Munizaga ve arkadaşları 1 km, Eldemir ve arkadaşları (2015) 500 metre olarak belirlemişlerdir. Bir sonraki binişe maksimum yürüme mesafesi içindeki duraklardan en kısa mesafeye sahip olan iniş durağı olarak belirlenir. 2. Varsayım uygulanırken akşam binişinin bulunduğu hattaki duraklardan sabahki biniş durağına maksimum yürüme mesafesi içindeki duraklardan en yakını iniş durağı olarak belirlenir.

Munizaga ve arkadaşları (2010 ve 2012) iniş durağını sonraki binişe göre belirlerken en kısa mesafenin hatalı sonuç verebileceğine dikkat çekerek geliştirilmiş zaman kavramını öne sürmüşlerdir.

Konum ve zaman olarak iniş tahmini bir sonraki biniş zaman ve konumu ile geliştirilmiş zaman mesafesini en aza indirir. Denklem 31’de geliştirilmiş zaman (T_{g_i}) i konumuyla ilgili zamana t_i , i konumuyla sonraki konum arasındaki mesafenin (d_{i-post}) ortalama yürüme hızına (s_w) oranı f_w ağırlık katsayısı ile çarpılarak eklenmesi şeklinde tanımlanır. Cezalandırma faktörü, f_w araç içi seyahat boyunca yürüme zamanının yararsızlığı olarak ayrık seçim modellerinden elde edilir. Pozisyon i ile ilişkili seyahat süresi t_i eksi biniş zamanı olarak elde edilebilir (Munizaga, 2010: 9).

$$T_{g_i} = t_i + f_w \cdot \frac{d_{i-post}}{s_w}$$

Denklem 31

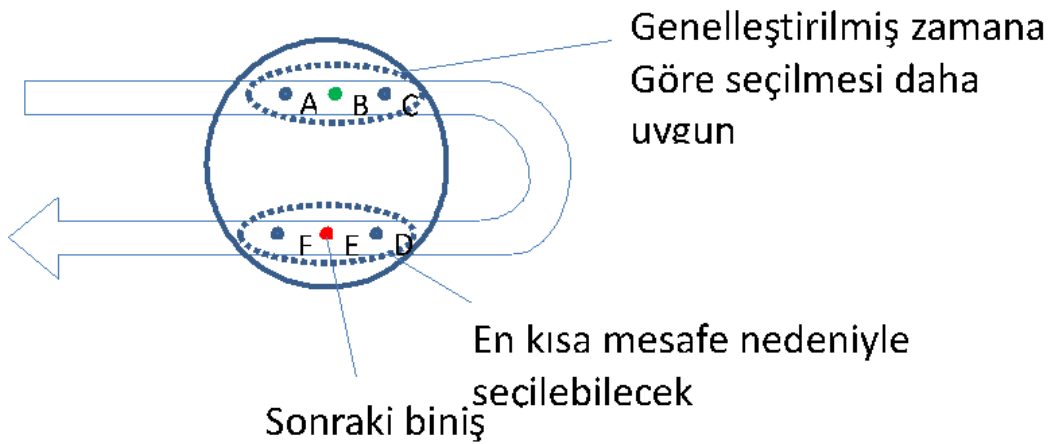
Arama, bir sonraki işlem pozisyonundan yürüme mesafesinde (d) olan otobüs güzergahının tüm pozisyonları üzerinden gerçekleştirilir. Bu nedenle, optimizasyon problemi şöyle yazılabilir:

$$\begin{array}{ll} \text{Min} & T_{g_i} \\ \text{s.t.} & \\ & d_{i-post} < d \end{array}$$

Denklem 32

Şekil 9’da en kısa mesafenin hataya neden olabileceği bazı durumlar gösterilmiştir.

Şekil 9: En Kısa Mesafenin Hataya Neden Olabileceği Özel Durumlar



Kaynak: Munizaga ve arkadaşları (2010 ve 2012)

Şekil 9'daki örnek bir hattın dönüş yönündeki bir sonraki biniş noktası "E" noktasıdır. Bu durağa maksimum yürüme mesafesi içinde kalan aday çözümler büyük elipsin kapsadığı bölümdeki duraklardır. Hem gidiş hem dönüş yönündeki duraklar bu kapsama alanında olduğundan en kısa mesafe kriterine göre muhtemelen dönüş yönündeki bu duraklardan (F ve D) birisi seçilecektir. Oysa genelleştirilmiş zaman kriterine göre seçim yapılırsa gidiş yönünde sonraki binişe en yakın durak seçilecektir. Çünkü biniş yönündeki duraklar için hesaplanacak genelleştirilmiş zamanlar dönüş yönü durakları için hesaplanandan çok daha küçük olacaktır.


Munizaga ve arkadaşları ayrıca varış noktaları ile aktarma noktalarını ayırmak için basit bir prosedür önermiştir. Tahmin edilen iniş ile sonraki biniş zamanı arasındaki fark hesaplanmıştır. Bu süre 45 dakikadan az ise bir aktarmayı aksi durumda ise bir varış noktasını göstermektedir (Munizaga, 2010: 12).

Barry ve arkadaşları (2009) iniş durakları belirlenemeyen binişler için iki yaklaşım önermişlerdir. Bunlardan ilki metro istasyonları için önerilmiştir. Bir iniş durağı, aynı istasyona iniş istasyonu olarak atanan kullanıcıların gözlenen dağılımına dayanan uniform örnekleme ile atanır. Otobüs yolcuları için, kullanılan hata deseniyle gün içinde aynı durakta binen yolcuların iniş dağılımına dayalı benzer bir yaklaşım kullanılır (Barry ve arkadaşları, 2009: 57). Diker 2015 yılındaki tez çalışmasında yolculuk zincirleme yöntemiyle tespit edilemeyen iniş durakları için rastgele atama tahmin yöntemini tanımlamıştır. Bu yöntem biniş ve iniş sayılarını dengelemeye çalışan ve mevcut iniş dağılımını korumaya çalışan bir yaklaşımdır (Diker, 2015: 7-8).

3.2. YAPAY SİNİR AĞLARI

Yapay sinir ağları-YSA, insan beyninin özelliklerinden olan öğrenme yolu ile yeni bilgiler türetebilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi yetenekleri olan bilgisayar algoritmalarıdır (Öztemel, 2012: 29). Tipik bir yapay sinir ağına örnek Şekil 10'da gösterilmiştir. Çok katmanlı algılayıcı tipindeki bu YSA'da giriş ve çıkış katmanlarının arasında bir gizli katman görülmektedir. Giriş katmanı verileri gizli katmana iletir. Gizli katmanda veri işlenir ve çıktı katmanına iletir. Çıktı katmanı sistemin çıktısını oluşturur.

Şekil 10: İleri Beslemeli Bir Yapay Sinir Ağı Modeli



Kaynak: Turgut, 2019:3.

3.2.1. Yapay Sinir Ağlarının Genel Özellikleri


Yapay sinir ağlarının karakteristik özellikleri uygulanan ağ modeline göre değişmektedir. Ancak bütün modeller için geçerli olan genel karakteristikler aşağıdaki gibi sıralanabilir (Öztemel, 2012: 31-33):

- **Yapay sinir ağları makine öğrenmesi gerçekleştirirler:** Yapay sinir ağlarının temel işlevi bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında doğru kararlar vermeye çalışırlar.
- **Programların çalışma stili bilinen programlama yöntemlerine benzememektedir:** Geleneksel programlama ve yapay zeka yöntemlerinin uyguladığı bilgi işleme modellerinden tamamen farklı bir bilgi işleme yöntemi vardır.
- **Bilginin saklanması:** Yapay sinir ağlarında bilgi ağın bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Ağın üzerindeki bilginin ortaya çıkarılması ve yorumlanması zordur.
- **Yapay sinir ağları örnekleri kullanarak öğrenirler:** Yapay sinir ağlarının olayları öğrenebilmesi için o olay ile ilgili örneklerin belirlenmesi gerekir. Örnekleri kullanarak ilgili olay hakkında genelleme yapabilecek yeteneğe kavuştururlar. Örnekler, gerçekleşmiş olaylardır. Örneğin bir doktor hastasına bazı sorular sorarak teşhis koyar ve ilaç yazar. Sorulan sorular ve cevaplar ile konulan teşhis bir örnek teşkil eder. Bir doktorun belirli bir sürede hastalarıyla diyalogları ve teşhisleri kaydedilir ve YSA bu verilerle eğitilirse, bir doktor gibi teşhis koyabilir. Ağa olay bütün yönleriyle gösterilemez ve ilgili örnekler sunulmaz ise başarılı sonuçlar elde edilemez.

- **Yapay sinir ağlarının güvenle çalıştırılabilmesi için önce eğitilmeleri ve performanslarının test edilmesi gereklidir:** YSA'ların eğitilmesi demek, mevcut örneklerin tek tek ağa gösterilmesi ve ağın öğrenme algoritmaları ile örnekteki olaylar arasındaki ilişkileri belirlemesidir. YSA ile çalışırken eldeki veriler eğitim ve test seti şeklinde iki kısma ayrılır. Ağ eğitim setindeki veriler ile eğitilir. Daha sonra ağın hiç görmediği test setindeki veriler ağa uygulanarak genelleme yeteneği ölçülür. Kabul edilebilir bir başarı sağlanırsa YSA kullanıma hazırdır. Başarı sağlanamamışsa ya eğitime devam edilir ya da yeni örneklerle eğitim yapılır.
- **Genelleme yapabilirler:** Ağ kendisine gösterilen örneklerden genellemeler yaparak görmediği örnekler hakkında bilgiler üretebilirler.
- **Algılamaya yönelik olaylarda kullanılabilirler:** YSA'lar algılama konusunda oldukça başarılıdır. Bazı durumlarda YSA'lar ile uzman sistemler birleştirilerek başarılı melez algoritmalar geliştirilebilir.
- **Şekil (örüntü) tanıma ve sınıflandırma yapabilirler:** Genel olarak ağların çoğunun amacı kendisine örnekler halinde verilen örüntülerin kendileriyle veya diğerleri ile ilişkilendirilmesidir. Diğer bir amaç ise sınıflandırma yapmaktır. Verilen örneklerin kümelendirilmesi ve belirli sınıflara ayrıştırılarak daha sonra gelen örneğin hangi sınıfa gireceğine karar vermesi hedeflenmektedir.
- **Örüntü tamamlama gerçekleştirebilirler:** Bazı durumlarda ağa eksik bilgileri içeren bir örüntü verilir ve ağın bu eksik bilgileri bulması istenebilir. Örneğin yırtık bir resmin kime ait olduğunun belirlenmesi ve tam resmin verilmesi gibi bir sorumluluk ağa yüklenebilir.
- **Kendi kendini organize etme ve öğrenebilme yetenekleri vardır:** YSA'larının örnekler ile kendisine gösterilen yeni durumlara adapte olması ve sürekli yeni olayları öğrenebilmesi mümkündür.
- **Eksik bilgi ile çalışabilmektedir:** YSA eğitildikten sonra eksik bilgiler ile çalışabilirler. Eğer eksik olan bilgi önemli bir bilgi ise ağın performansı düşer, aksi durumda ağın performansı yeterli olacaktır.
- **Belirsizlik durumunda da verileri işleyebilirler:** YSA olayları öğrendikten sonra belirsizlik koşulları altında olaylar arasındaki ilişkileri kullanarak karar verebilirler.

- **Dağıtık belleğe sahiptir:** YSA'da bilgi ağın bağlantılarına yayılmıştır. Tek bir bağlantının bir anlamı yoktur. Ancak ağ tüm bağlantılardaki bilgiyi kullanarak olayın bütününe karakterize ederler.
- **Sadece nümerik verilerle çalışırlar:** YSA'ları sadece sayısal verileri işleyebilirler. Sembolik ifadelerin sayısal verilere dönüştürülmesi gerekir.

Şekil 11'de doğal ve yapay sinir hücrelerinin yapısı görülmektedir. YSA'larda bağlantılara uygulanan girdiler, bağlantıların ağırlık katsayıları ile çarpılıp toplanırlar. Bu işleme toplama fonksiyonu adı verilir. Bias adı verilen eşik değeri verisi de işlenerek toplama fonksiyonunun sonucu aktivasyon fonksiyonuna iletilir. Sinir ağı aktivasyon fonksiyonunun özelliğine göre bir çıktı verir.



Kaynak: Psikolojik.gen.tr, 2019:1.

Yapay sinir hücrelerinde çeşitli aktivasyon fonksiyonları kullanılmaktadır: doğrusal aktivasyon fonksiyonu, Birim basamak aktivasyon fonksiyonu, hiperbolik tanjant aktivasyon fonksiyonu, sigmoid aktivasyon fonksiyonu vb.

3.2.2. Yapay Sinir Ağlarının Gelişimi

Yapay sinir ağlarının gelişimi 1954'den bu yana çok hızlı bir şekilde gelişmiş ve çok farklı alanlarında kullanılabilir hale gelmiştir. Bu alandaki gelişmeler Tablo 3'te kısaca özetlenmiştir.

Tablo 3: Yapay Sinir Ağı Alanında Yapılan Akademik Çalışmalar

Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
Farley ve Clark	1954	Simulation of Self-Organizing Systems by Digital Computer	Makale	Yazarlar kendi kendini düzenleyen sistemler ve bunların sentezlerine ilişkin fikir ve tanımları tartışmıştır.
Rosenblat	1958	The Perceptron: A Probabilistic Model For Information Storage and Organization	Makale	Yazar insan beynindeki sınırlardan yola çıkarak en basit algılayıcı türündeki yapay sinir hücresini tanımlamıştır.
Widrow ve Hoff	1960	Adaptive Switching Circuits	Makale	Yazarlar Adaptive Linear Unit - ADALINE ve Multiple Adaptive Linear Unit - MADALINE isminde birden çok sinir hücresi içeren ilk yapay sinir ağı modelini geliştirmişlerdir.
Kohonen	1972	Correlation Matrix Memories	Makale	Yazar Korelasyon Matris Hafızası isminde (Correlation Matrice Memory) bir algoritma geliştirmiştir.
Grossberg	1976	Adaptive Pattern Classification and Universal Recoding: II. Feedback, Expectation, Olfaction, Illusions	Makale	Yazar uyarlanabilir rezonans ağı (Adaptive Resonance Theory – ART) modelini geliştirmiştir.
Kohonen	1982	Self-Organized Formation of Topologically Correct Feature Maps	Makale	Kohonen kendi kendini organize eden özellik haritaları (Self Organized Map – SOM) ismini verdiği yapay sinir ağını geliştirmiştir.
Kohonen	1984	Self Organization and Associative Memory	Kitap	Yazar Öğrenme vektör nicelendirme (Learning Vector Quantization – LVQ) ağını geliştirmiştir.
Carpenter ve Grossberg	1986	Category Learning And Adaptive Pattern Recognition: A Neural Network Model	Bildiri	Yazarlar Grossberg'in 1976'da geliştirdiği ART ağını daha da geliştirerek ART2 ağını sunmuşlardır.
Carpenter ve Grossberg	1987	Art2: self-organization of stable category recognition codes for analog input patterns	Makale	Yazarlar ART2 ağını daha geniş bir şekilde tanıtmışlardır.
Fukushima	1975	Cognitron: A Self-Organizing Multilayered Neural Network	Makale	Yazar insan görme sisteminin yerine geçmesi amacıyla Cognitron adını verdiği bir yapay sinir ağı geliştirmiştir.
Fukushima ve Miyake	1982	Neocognitron,: A New Algorithm for Pattern Recognition Tolerant of Deformations and Shifts in Position.	Makale	Yazarlar Cognitron modelini elden geçirip geliştirerek Neocognitron adını verdikleri daha etkin bir yapay sinir ağı geliştirmişlerdir.

Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
Hopfield	1982	Neural Networks and Physical System with Emergent Collective Computational Abilities	Bildiri	Yazar kendi ismiyle anılan geri beslemeli yapay sinir ağını geliştirmiştir. Bu sinir ağı optimizasyon amacıyla kullanılabilir.
Ackley vd.	1985	A Learning Algorithm for Boltzmann Machines	Makale	Yazarlar istatistiksel mekanizmalara dayanan paralel arama algoritması olarak tanımladıkları Boltzman Makinelerini geliştirmişlerdir.
Rumelhart vd.	1986	Learning Internal Representation by Error Propagation	Kitap Bölümü	Yazarlar çok katmanlı algılayıcılar için geri yayılım algoritmasını (Backpropagation) geliştirmişlerdir ve XOR probleminin çözümünde etkin bir şekilde kullanmışlardır.
Broomhead ve Lowe	1988	Radial Basis Functions, Multi-Variable Functional Interpolation and Adaptive Networks	Bildiri	Yazarlar “Radyal tabanlı fonksiyon” ismini verdikleri YSA modelini sunmuşlardır.
Specht	1988	Probabilistic Neural Networks for Classification, Mapping, or Associative Memory	Bildiri	Yazar olasılık temeline dayanan “Olasılık temelli sinir ağı – Probabilistic Neural Network” ismini verdikleri bir model geliştirmiştir..
Chua ve Lin	1988	Cellular Neural Networks: Theory	Makale	Yazarlar, “Hücrel Sinir Ağları” adını verdikleri YSA modelini önermişlerdir.
Elman	1990	Finding Structure in Time	Makale	Yazar çok katmanlı algılayıcılara gizli katmandaki çıktıları hatırlatan ve belirli bir gecikme içeren içerik elemanlarını eklemiştir. Bu yapı bir tür geri beslemeli ağ yapısıdır.
Buntine ve Weigend	1991	Bayesian Backpropagation	Makale	Yazarlar Bayes yöntemine dayalı geri yayılım algoritmasını önermişlerdir.
Specht	1991	A General Regression Neural Network	Makale	Yazar “Genel Regresyon Ağları” ismini verdiği YSA modelini geliştirmiştir.
Berenji	1992	An Architecture for Designing Fuzzy Controllers Using Neural Networks	Makale	Yazar, sinir ağlarını kullanarak bulanık denetleyicileri tasarlamak için bir mimari geliştirmiştir
Boser ve arkadaşları	1992	A Training Algorithm for Optimal Margin Classifiers	Bildiri	Yazarlar, “Destek Vektör Makineleri – Support Vector Machines” adını verdikleri YSA modelini duyurmuşlardır.
Zhang ve Constantinides	1992	Lagrange Programming Neural Networks	Makale	Yazarlar “Lagrange programlama sinir ağları” adını verdikleri bir YSA modeli tanıtmışlardır
Zhang ve Benveniste	1992	Wavelet Networks	Makale	Yazarlar sinyal işleme için dalgacık dönüşümü ile sinir ağlarını birleştiren “Dalgacık ağlarını” önermişlerdir.


Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
He	1993	Theory, Application and Related Problems of Double Parallel Feedforward Neural	Teknik Rapor	Yazar “Çift Paralel İleri Beslemeli Sinir Ağı - Double Parallel Feedforward Neural Networks” modelini geliştirmiştir..
Lewestein	1994	Quantum Perceptrons	Makale	Yazar Quantum fiziğinden esinlenerek “Kuantum Algılayıcı –Quantum Perceptron” modelini geliştirmiştir.
Kak	1995	Quantum Neural Computing	Makale	Yazar “Kuantum sinir ağını – Quantum Neural Network” önermiştir.
LeCun ve arkadaşları	1998	Gradient-based Learning Applied to Document Recognition	Bildiri	Yazarlar, harf tanıma için “Convolutional Neural Network” modelini önermişlerdir.
Simard ve arkadaşları	2003	Best Practices for Convolutional Neural Networks Applied to Visual Document Analysis	Bildiri	Yazarlar evrişimsel sinir ağlarını tanıtmışlar ve harf tanımda oldukça başarılı olduğunu göstermişlerdir.
Huang ve arkadaşları	2006	Extreme Learning Machine: Theory and Applications	Makale	Yazarlar, Aşırı öğrenen makine – Extreme learning machine” modelini tanıtmışlardır.
Hinton ve arkadaşları	2006	A Fast Learning Algorithm for Deep Belief Nets	Makale	Yazarlar çok sayıda gizli katman bulunan, örüntü tanımda kullanılan derin inanç ağlarını önermişlerdir.
Desjardins ve Bengio	2008	Empirical Evaluation of Convolutional RBMs for Vision.	Teknik Rapor	Yazarlar bu çalışmada Evrişimsel Kısıtlı Boltzman Makinesi modelini önermişlerdir.
Hsu	2011	Using a Back Propagation Network Combined with Grey Clustering to Forecast Policyholder Decision to Purchase Investment-Linked Insurance	Makale	Yazar, gri kümeleme algoritması ile geri yayılım ağlarını birleştiren bir YSA modeli önermiştir
Ge ve Xu	2013	Stability Switches and Fold-Hopf Bifurcations in an Inertial Four-Neuron Network Model with Coupling Delay	Makale	Yazarlar ataletli gecikmeli çift yönlü ilişkisel hafıza türünde 4 nöronun dinamiklerini incelemişlerdir.
Goodfellow ve arkadaşları	2014	Generative Adversarial Networks	Bildiri	Yazarlar “Üretken ters ağlar” ismini verdikleri bir model önermişlerdir.
Bengio ve arkadaşları	2014	Deep Generative Stochastic Networks Trainable by Backprop	Bildiri	Yazarlar bu çalışmada markov zincirlerine dayalı “Geri yayılım ile eğitilebilen derin üretken stokastik ağ” adını verdikleri bir model önermişlerdir.
Raissi ve arkadaşları	2017	Physics Informed Deep Learning (Part I): Data-Driven Solutions of Nonlinear Partial Differential Equations	Makale	Yazarlar doğrusal olmayan denklem sistemleri çözümü için fizik bilgisi sinir ağı yaklaşımını geliştirmişlerdir.

Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
Feng ve arkadaşları	2019	Rough Extreme Learning Machine: a New Classification Method Based on Uncertainty Measure	Makale	Yazarlar sınıflandırma için kaba küme yaklaşımını kullanan kaba aşırı öğrenme makinesi adını verdikleri sinir ağını önermişlerdir.

3.2.3. Yapay Sinir Ağı Türleri

Yapılarına göre YSA'ları ileri beslemeli ve geri beslemeli olmak üzere ikiye ayrılmaktadır. Şekil 12 ileri ve geri beslemeli ağ yapısını göstermektedir.


Şekil 12: İleri ve Geri Beslemeli Yapay Sinir Ağları



İleri beslemeli YSA'larında bilgiler tek yönlü olarak girdi katmanından çıktı katmanına doğru akar. Geri beslemeli ağlarda ise veriler hem girdi katmanından çıktı katmanına doğru akar, hem de çıktı katmanındaki veriler YSA'ya yeniden girdi olarak verilir. Özellikle zaman serisi analizlerinde kullanılan YSA modellerinde bu yaklaşım kullanılmaktadır.

Öğrenme algoritmalarına göre yapay sinir ağları: Danışmanlı öğrenme, danışmansız öğrenme, destekleyici öğrenme ve karma öğrenme algoritmalarına sahip YSA olarak dört ana başlıkta incelenebilir. Bu yapılar Şekil 13'de gösterilmiştir.

Şekil 13: Öğrenme Yöntemlerine Göre Yapay Sinir Ağları



Çok katmanlı algılayıcılarda giriş katmanından örnekler uygulanır ve çıkış katmanında elde edilen çıktı ile beklenen değer karşılaştırılarak hata hesaplanır. Hesaplanan bu hata geri yayılım algoritması veya gradyan temelli bir algoritma ile tüm ağı yayılarak ağı bağlantılarındaki ağırlık katsayıları güncellenir. Ağ bu şekilde eğitilir. LVQ ağlarında girdi katmanına veriler uygulandığında istenen çıktı elde edilirse bağlantıların ağırlıkları aynı çıktıyı vermesi için pozitif yönde güncellenir. Eğer çıktı istenenden farklı ise bu örnek tekrar gösterildiğinde aynı çıktıyı vermemesi için negatif yönde güncelleme yapılır. Ağ bu şekilde eğitilir. Uyarlanabilir rezonans ağlarında ise çıktıyla ilgili herhangi bir karşılaştırma yapılmaz. Ağ kendi iç dinamiklerindeki süreçlerle bağlantıların ağırlıklarını günceller ve öğrenir. Radyal Tabanlı Ağ (Radial-Basis Network – RBN) ve Olasılıksal Sinir Ağları (Probabilistic Neural Network – PNN) bu öğrenme yöntemlerinden karma olarak yararlanmaktadır.

3.2.4. Yapay Sinir Ağlarının Kullanım Alanları

Yapay sinir ağları günümüzde hemen her bilim dalında yaygın bir kullanıma sahiptir. Veri madenciliğinde, optik karakter tanımda, kredi başvurularının değerlendirilmesinde, ürünün pazar başarısını tahmin etmede, kredi kartı hilelerini saptamada, zeki araçlar ve robotlar için optimum rota belirlemede, konuşma ve parmak izi tanımda, kontrol sistemlerinde, arıza tahmininde, kalite kontrolünde, iş çizelgeleme ve iş sıralamada, radar ve sonar sistemlerinde sinyalleri sınıflandırmada, üretim planlama ve çizelgelemede, kan analizlerini sınıflamada, hastalıkların teşhis edilmesinde, beynin modellenmesine yönelik çalışmalarda kullanılmaktadır. Ayrıca silah sanayinde güdümlü sistemleri, kontrol mekanizmaları ve şifreleme sistemlerinde kullanılmaktadır.

Çuhadar ve Kayacan 2005'deki çalışmalarında 1990-2001 yılları arasındaki zaman diliminde Türkiye'deki otellerin doluluk oranları ile 2 gizli katmana sahip bir yapay sinir ağını eğitmiş ve ağı tahminleme yeteneğini test etmişlerdir. Deneysel çalışmalarda hesaplanan MSE, RMSE ve MAPE değerleri yapay sinir ağı tahminlemede başarılı olduğunu göstermiştir (Çuhadar ve Kayacan, 2005).

Çuhadar 2006'daki doktora tezinde, Ocak 1992 – Aralık 2005 dönemine ait Antalya iline gelen aylık yabancı turist sayısı verileri kullanarak, 2004 ve 2005 yılları için mekanik tahmin, hareketli ortalamalar, üstel düzleştirme ve Box Jenkins yöntemlerinden, verilerin yapısına uygun modeller ve farklı mimarilere sahip yapay

sinir ağı modellerinden faydalanarak Antalya iline yönelik örnek içi ve örnek dışı aylık yabancı turist sayısı öngörülerini yapmıştır. Taleplerin gerçekçiliğine ilişkin hesaplanan istatistikler yapay sinir ağına daha başarılı olduğunu göstermiştir (Çuhadar, 2006).

Adıyaman 2007 yılındaki yüksek lisans tezinde, 1997-2005 arasındaki 108 adet veriyi, ağı eğitimi ve testi için kullanmıştır. Bunlardan 93 tanesi eğitim, 15 tanesi doğrulama için seçilmiştir. 2006 verileri ise sonucun testi için kullanılmıştır. Yapay Sinir Ağ yapısı birçok talep tahmininde kullanıldığı gibi bir gizli katman olmak üzere üç katmanlı yapı seçilmiştir. Girdi katmanı 9 hücreden, çıktı katmanı ise 2 çıktı hücreden oluşmuştur. Yapılan tahmin sonucunda işçilik değeri yüksek ürünler için %98,7 oranında bir başarı elde edilirken, işçilik değeri düşük ürünler için %97,7 oranında başarı elde edilmiştir. Ortalama başarı oranı ise %98,2 olarak gerçekleşmiştir. Yazar YSA'nın regresyon analizi ve eğri uydurma yöntemlerinden daha başarılı olduğunu raporlamıştır (Adıyaman, 2007).

Çuhadar ve arkadaşları 2009'daki çalışmalarında yapay sinir ağı, Box-Jenkins ARIMA(1,0,0)(0,1,1)¹² ve Mevsimsel Üstel Düzleştirme (Winters) yöntemleri ile Antalya İli'ndeki turizm talebini tahminlemişler ve yöntemleri karşılaştırmışlardır. Yazarlar MAPE değerine göre en iyi sonuç veren yöntemin yapay sinir ağı yaklaşımı olduğunu göstermişlerdir (Çuhadar vd., 2009).

Önder ve Hasgöl 2009 yılındaki makalelerinde 1986 Ocak -2007 Ekim dönemleri arası gelen yabancı turistlere ilişkin 262 aylık değere sahip veri seti kullanmışlardır. Bu veri setiyle eğitilen YSA, Doğrusal ve Mevsimsel Üstel Düzgünleştirme Yöntemi ve Box-Jenkins Yöntemine yakın bir performans göstermiştir (Önder ve Hasgöl, 2009).

Yücesoy 2011'deki yüksek lisans tezinde 1981-2010 arasında yıllık bazda kağıt ürünleri satış verileri toplanmış, 1981-2009 arasındaki verileri eğitim amaçlı, 2010 yılı verisini ise test amaçlı kullanmıştır. Veriler girdi ve çıktı verileri olarak aşağıdaki gibi toplanmıştır: Üretim Miktarı, İthalat Miktarı, Kâğıt ve Basım Sanayi Toptan Eşya Fiyat Endeksi (TEFE), Gayri Safi Yurtiçi Hâsıla, Genel Nüfus, Kentli Nüfus, Okuryazar Oranı. Yapılan talep tahmini sonucunda %1,11'lik bir hatayla %98,89 başarı elde edilmiştir (Yücesoy, 2011).

Karahan, 2015 yılındaki makalesinde, tahmin işlemini yapması için belirlenen turizm talep miktarını etkileyen altı değişkene ait dönemsel veriler, Ocak 2010 tarihinden Aralık 2013 sonuna kadar 48 aylık (4 yıl) olarak düzenlenmiştir. Modelin bağımlı değişkeni, aylık turist sayısıdır. Bağımsız değişkenleri ise; turizm dönemleri,

ilgili dönemlerdeki hava sıcaklıkları, turizm gelirleri, döviz kurları, aylık Tüketici Fiyat Endeksi - TÜFE ve yıllık TÜFE değerleridir. Çalışmada, YSA modelinin MAPE hata değeri 0,0986 (% 9,9) olarak hesaplanmıştır (Karahana, 2015).

3.3. HEDEF PROGRAMLAMA

“Hedef programlama (HP) tekniğı, Yöneylem Araştırması'nda yaygın olarak kullanılan bir yaklaşım haline gelmiştir. HP modeli ve varyantları büyük ölçekli çok kriterli karar verme problemlerini çözmek için uygulanmıştır. HP tekniğı ilk kez 1960'larda Charnes ve Cooper tarafından kullanılmıştır (Charnes vd., 1955; Charnes ve Cooper, 1961). Bu çözüm yaklaşımı Ijiri (1965), Lee (1972) ve diğerleri tarafından genişletilmiştir. Hedef programlama, çok yönlü karar verme problemlerini ele almak için geliştirilen modellerden biridir. Hedef programlama tekniğı bir karar vericinin çoklu ve çelişen hedeflere en uygun çözümleri sunmak için kullanabileceğı analitik bir çerçevedir” (Sen ve Nandi, 2012: 1).

“Hedef Programlama, verilen kısıtlayıcılar altında amaç kriterini doğrudan maksimum veya minimum kılmaktan ziyade hedeflerin kendi içindeki sapmalarını minimum kılmaya odaklanmaktadır” (Jones ve Tamiz 1997'den aktaran Uludağ, 2010: 46). “Hedeflerden sapmalar, yani bir hedefin aşılması (pozitif sapma), bir hedefin altında kalınması (negatif sapma) değerleri toplamını minimize edilmesi bir tek amaç olarak ortaya konulabilir. HP bu sapmaları en az yaparak çözüm arar” (Bal 1995'den aktaran Uludağ, 2010: 46).

3.3.1. Hedef Programlamanın Uygulama Alanları

Hedef programlama birçok gerçek hayat problemine uygulanabilir. Uygulama alanlarından bazıları: Ulaştırma problemleri, lojistik, üretim planlaması, enerji planlaması, işgücü planlaması, proje seçimi ve yönetimi, portföy seçimi, finansal planlama, pazarlama, beslenme problemleri, yatırım planlaması, toplam kalite yönetimi, tedarikçi seçimi, tarımsal üretim ve yönetim, kuruluş yeri seçimi, fabrika yerleşim planlaması, rota planlaması, sağlık hizmetleri planlaması, satın alma planlaması, hastanelerde kaynak planlaması, Genel bütçe planlaması, stok yönetimi, yükleme problemleri, vb. şeklindedir.

3.3.2. Karar Değişkenlerinin Belirlenmesi

Hedef programlama yöntemine ve uygulama alanına uygun olarak karar değişkenleri belirlenir. Karar değişkenlerinin açık ve doğru şekilde ifade edilmesi, modelin oluşturulmasını kolaylaştırır.

3.3.3. Sistem Kısıtlarının Belirlenmesi

Sistem kısıtları kesinlikle sağlanması gereken ve hiçbir sapmaya izin verilmeyen kısıtlayıcılardır (Öztürk, 2007'den aktaran Uludağ, 2010: 46). Söz konusu bu kısıtlar, eldeki kısıt kaynakları ifade ederler (Ignazio, 1985'den aktaran Uludağ, 2010: 46).

3.3.4. Hedef Kısıtlarının Belirlenmesi

Karar vericiyi tatmin edecek hedef kısıtlarının belirlenmesi önemlidir. Hedef kısıtları için öncelikle sağ taraf sabitleri tanımlanır. Daha sonra kısıtlardaki uygun teknolojik katsayılar ve karar değişkenleri ve sapma değişkenleri kısıtlara ilave edilir. Hedef kısıtları için üç durum söz konusudur.

$$f_i(x) > b_i$$

Denklem 33

$$f_i(x) \leq b_i$$

Denklem 34

$$f_i(x) = b_i$$

Denklem 35

b_i değerini aşma miktarını gösteren d_i^+ ve b_i değerinin altında olma durumunu gösteren d_i^- sapma değişkenlerini ifade eder.

Burada, Denklem 33 bağıntısı için $f_i(x) > b_i$ olduğunda istenen durum $d_i^+ \geq 0$ olmasıdır. d_i^- değişkeninin olabildiğince sıfıra yakın olması gerekir; d_i^+ kısıtlanmayan sapmadır. Mümkün olan sapmalar d_i^+ ve d_i^- 'dir. Sağ taraf için istenen durum b_i ve daha büyük iken istenmeyen sapma değişkeni d_i^- 'dir. Amaç fonksiyonunda yer alması ve minimize edilmesi gereken sapma değişkeni de d_i^- 'dir.

Denklem 34 için $f_i(x) \leq b_i$ olduğunda istenen durum $d_i^- \geq 0$ olmasıdır. Kısıtlanmayan sapma d_i^+ değişkeninin mümkün olduğunca sıfıra yakın olması arzulanır. Mümkün sapmalar d_i^- ve d_i^+ iken sağ taraf sabitinin istenen durumu b_i ve daha azdır. Amaç fonksiyonunda yer alması gereken ve minimize edilmesi gereken sapma değişkeni d_i^+ 'dir.

Denklem 35 için $f_i(x) = b_i$ olduğunda ise istenen durum d_i^+ ve d_i^- 'nin sıfıra eşit olması olup kaynakların tamamının kullanıldığı durumda söz konusudur. Hiçbir sapma değişkeni kısıtlanmamış olup sağ taraf sabitinin b_i 'ye eşit olması istenen durumdur. Amaç fonksiyonunda yer alması gereken ve minimize edilmesi gereken değişkenler d_i^- ve d_i^+ 'dir.

Hedefler arasında bir öncelik veya önem sırasının olup olmama durumu belirlenmelidir. Verilen önceliklere göre amaç denklem oluşturulacaktır. Modelde hedeflerin önceliklerin belirlenmesine bağlı olarak ağırlıklar tanımlanır. Tamamen subjektif özelliğe sahip olup karar vericinin isteğine göre tanımlanır.

3.3.5. Amaç Denklemin Tanımlanması

Karar vericinin istekleri, kaynakları ve kontrol değişkenleri için oluşturulan kısıtlama koşulları göz önüne alınarak oluşturulur. Modelde hedef kısıtları dikkate alınarak amaç fonksiyonunda gerekli sapma değişkenleri belirlenir ve hedef kısıtlarının öncelik sıralamasına bağlı olarak sapma değişkenleri minimize edilmeye çalışılır. Amaç fonksiyonları karar vericiye göre beş farklı şekilde ifade edilir (Öztürk 2007'den aktaran Uludağ, 2010: 46). Bu durumlar aşağıda belirtilmiştir;

Amaç fonksiyonu,

Tek hedefli bir doğrusal hedef programlama modelinde;

$$\text{Min } Z = d_i^+(p_i) \text{ veya } \text{Min } Z = d_i^-(p_i) \quad \text{Denklem 36}$$

Eşit ağırlıklı (öncelikli) ya da öncelikli olmayan çok hedefli programlama modelinde;

$$\text{Min } Z = \sum_{i=1}^m (d_i^+ + d_i^-) \quad \text{Denklem 37}$$

Öncelikli çok hedefli programlama modelinde;

$$\text{Min } Z = \sum_{i=1}^m p_k (d_i^+ + d_i^-), \quad p_1 \gg p_2 \gg p_3 \dots \gg p_k \quad \text{Denklem 38}$$

Çözüm prosedürü en yüksek öncelikli hedeften başlayıp en düşük öncelikli hedefle bitirilerek her seferde tek hedefli bir problemi çözer. Düşük öncelikli bir hedefle elde edilen çözüm, yüksek öncelikli hedefle bulunmuş çözümleri

kötüleştirmez. Hedef programlama literatüründe bunu sağlamak için sütun ekleme kuralı içeren özel bir simpleks algoritması kullanılır (Taha, 2007: 352).

Ağırlıklı çok hedefli programlama modelinde;

$$\text{Min } Z = \sum_{i=1}^m w_{ik}(d_i^+ + d_i^-) \quad \text{Denklem 39}$$

şeklinde olup, amaç fonksiyonundaki sapma değişkenlerine ağırlık verilen bu yaklaşım, eşit öncelikli çok hedefli problemlerin sapma değişkenlerinin ölçü birimleri farklı olduğunda kullanılır. Burada w_{ik} i. hedeften oluşan sapmaya ilişkin ağırlığı göstermektedir.

Ağırlıklı – öncelikli çok hedefli programlama modelinde;

$$\text{Min } Z = \sum_{k=1}^m \sum_{i=1}^m P_k [w_{ik}(d_i^+ + d_i^-)] \quad \text{Denklem 40}$$

şeklinde. Birden fazla hedefin aynı öncelik düzeyine sahip olduğu durumlarda sapma değişkenlerini ağırlıklandırma ile farklılaştırarak bir amaç fonksiyonu oluşturulmaya çalışılmaktadır (Öztürk 2004'den aktaran Uludağ, 2010: 46).

3.4. GENETİK ALGORİTMALAR

3.4.1. Genetik Algoritma Kavramı ve Gelişimi

“Evrimsel programlamanın bir parçası olan genetik algoritmalar (GA) Darwin’in evrim teorisinden esinlenerek ortaya çıkmıştır. 1960’lı yıllarda I.Rechenberg’in ‘Evrimsel Stratejileri’ adlı kitabıyla gündeme gelmiştir (Nabiyev, 2005: 632)”.

Genetik algoritma fikri J. Holland (1975)’a aittir. Holland, arkadaşları ve öğrencileri ile birlikte bu algoritmayı geliştirmiş ve ilk çalışmalarının sonucunda “Doğal ve Yapay Sistemlerde Adaptasyon – Adoption in Natural ve Artificial Systems” isimli kitabını çıkarmıştır.

Genetik algoritmalar doğal seçim ve doğal genetik mekanizmalara dayanan arama algoritmalarıdır. Bu yöntemler, bir arama algoritması kurmak için rasgele bilgi değişimi ile dizi yapılarının arasında en iyinin kurtulması ve insan araştırmasının yenilikçi sezgisel gücünü birleştirirler. Her nesilde, önceki neslin en iyisinin tesadüfi yeni bir parçası denenerek, bitlerinin ve parçalarının kullanılması sonucu yeni yapay

diziler oluşturulur. Genetik algoritmalar basit rasgele arama yapmazlar, onlar geçmiş bilgilerden yararlanarak yeni araştırma noktaları düşünürler (Goldberg, 1989: 18).

Holland (1975), basit bit dizileri (bit strings) kullanarak karmaşık yapıların kodlanabileceğini göstermiştir. Yapılar, çözülecek problem için çözümleri temsil etmektedir ve dizi, kromozom ya da birey adı verilmektedir. Bunlar, problemin araştırma uzayından alınırlar ve bu dizilerin belirli bir miktarı genetik algoritmanın kullanacağı popülasyonu oluşturur. Daha sonra temel genetik operatörler kullanılarak çözümler geliştirilir ve yeni nesiller üretilir. Eğer bu işlemler iyi kontrol edilirse, çözülecek probleme çok iyi uyarlanmış yapıları içeren çözüm kümesinin ortaya çıkmasını sağlar. Genetik Algoritmanın gelişimine ilişkin tarihsel süreç Tablo 4’de gösterilmiştir.

Tablo 4 : Genetik Algoritmanın Tarihsel Gelişim Süreci

Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
Rechenberg	1973	Evolution Strategies	Kitap	Yazar kitabında Darwin’in evrim terorisinden yola çıkarak Evrim Stratejileri adını verdiği algoritmaları oluşturmuştur.
Holland	1975	Adaptation in Natural ve Artificial Systems	Kitap	Yazar kitabında genetik algoritma fikrini geliştirmiş ve uygulamıştır.
Goldberg	1989	Genetic Algorithms in Search, Optimization, and Machine Learning	Kitap	Yazar kitabında genetik algoritma ve gelişimini aktarmış, gelişmiş operatörleri tanıtmış ve genetik algoritmanın makine öğrenmesinde kullanımını göstermiştir.
Bean	1994	Genetic Algorithms and Random Keys for Sequencing and Optimization	Makale	Yazar rasgele anahtar ismini verdiği [0,1] aralığındaki sayılarla kromozomların oluşturulduğu ve gen değerlerinin bu anahtarlara göre küçükten büyüğe sıralandıklarındaki sıra numarası olarak belirlendiği bir genetik algoritma önermiştir. Yeni nesil oluşturulurken: eski neslin en iyi %20’si aynen yeni nesile akatarılır, %79’una çaprazlama uygulanır ve %1’i rasgele üretilir.
Chiu ve Yih	1995	A Learning-Based Methodology for Dynamic Scheduling in Distributed Manufacturing Systems.	Makale	Yazarlar dinamik çizelgeleme probleminde genetik algoritma tabanlı bir uygulama geliştirmiştir.
Adeli ve Kumar	1995	Concurrent Structural Optimization on Massively Parallel Supercomputer	Bildiri	Yazarlar optimizasyon için bir paralel genetik algoritma geliştirmişlerdir.

Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
Dagli ve Sittisathanchai	1995	Genetic Neuro-Scheduler: A New Approach for Job Shop Scheduling	Makale	Yazarlar genetik algoritma ve yapay sinir ağını birleştirerek atölye çizelgelemede etkin bir algoritma geliştirmişlerdir.
Whitehead	1996	Genetic Evolution of Radial Basis Function Coverage Using Orthogonal Niches	Makale	Yazar genetik algoritma ile en iyi radyal tabanlı fonksiyonu elde eden bir algoritma geliştirmiştir.
Nagar ve arkadaşları	1996	A Combined Branch-and-Bound and Genetic Algorithm Based Approach for A Flowshop Scheduling Problem	Makale	Yazarlar akış tipi çizelgeleme için dal-sınır algoritması ile genetik algoritmayı birleştiren yeni bir algoritma geliştirmiştir.
Soh ve Yang	1996	Fuzzy Controlled Genetic Algorithm Search for Shape Optimization	Makale	Yazarlar bu çalışmada bulanık bilgi tabanlı sistem ile genetik algoritmayı kontrol etmişlerdir.
Murata ve arkadaşları	1996	Multi-Objective Genetic Algorithm and Its Applications to Flowshop Scheduling	Makale	Yazarlar akış tipi çizelgeleme problemi için süreyi ve toplam gecikmeyi minimize eden çok ölçütlü bir genetik algoritma geliştirmişlerdir.
Kubota ve arkadaşları	1996	Virus-Evolutionary Genetic Algorithm for a Self-Organizing Manufacturing System	Makale	Yazarlar genetik algoritmada her yeni nesil oluşturulurken çaprazlama ve mutasyon adımlarından sonra virüs enfeksiyon operatörü uygulamışlardır.
Kim ve arkadaşları	1998	A Heuristic-Based Genetic Algorithm for Workload Smoothing in Assembly Lines	Makale	Yazarlar genetik algoritmada montaj hattı dengeleme problemine özel sezgisel çaprazlama ve mutasyon operatörlerinin daha başarılı olabileceğini göstermiştir.
Cormier ve arkadaşları	1998	A Constraint-Based Genetic Algorithm for Concurrent Engineering	Makale	Yazarlar bu çalışmada kısıt tabanlı başlatma prosedürü, çaprazlama ve mutasyon operatörü geliştirmiştir. Yazarlar, geliştirdikleri genetik algoritmaya bu nedenle kısıt tabanlı genetik algoritma ismini vermişlerdir.
Charon ve Hudry	1998	Lamarckian Genetic Algorithms Applied to the Aggregation of Preferences	Makale	Yazarlar çalışmalarında genetik algoritmayı başlatırken ve genetik operatörleri uyguladıktan sonra tekrarlı iniş, yapay ısı işlem, basit gürültü ve ısı gürültü sezgisellerini uygulamıştır. Bu türdeki melezleştirmeye Lamarckçı genetik algoritma adı verilmektedir.
Da Silva ve arkadaşları	2000	Transmission Network Expansion Planning Under an Improved Genetic Algorithm	Bildiri	Yazarlar bu çalışmada yapay ısı işlem ile kontrol edilen mutasyon operatörü kullanmışlardır. Ayrıca son popülasyona tabu arama algoritması uygulanarak her birey için yerel arama yapmışlardır.

Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
Wang ve Jiao	2000	A Novel Genetic Algorithm Based on Immunity	Bildiri	Yazarlar biyolojideki bağışıklık teorisine dayanan “Bağışık genetik algoritma” ismini verdiği bir algoritma geliştirmiştir.
Grigorenko ve Garcia	2000	An Evolutionary Algorithm to Calculate The Ground State of a Quantum System	Makale	Yazarlar quantum dünyası için genetik algoritmayı uyarlayarak kuantum genetik algoritmasını önermişlerdir.
Huang ve arkadaşları	2001	An integrated neural-fuzzy-genetic-algorithm using hyper-surface membership functions to predict permeability in petroleum reservoirs	Makale	Yazarlar petrol depolarındaki geçirgenliğin tahmininde genetik algoritmalarla sinirsel-bulanık sistemi birleştiren yeni bir tekniği önermişlerdir.
Falco ve arkadaşları	2002	Mutation-based genetic algorithm: performance evaluation	Makale	Yazarlar çaprazlama içermeyen sadece mutasyon operatörü içeren bir genetik algoritma önermiş ve çeşitli genetik algoritma türleri ile karşılaştırmışlardır. Önerdikleri algoritmanın etkili sonuç verdiğini raporlamışlardır.
Hsu ve arkadaşları	2003	The Hybrid of Association Rule Algorithms and Genetic Algorithms for Tree Induction: An Example of Predicting The Student Course Performance.	Makale	Yazarlar öğrencilerin akademik başarısını tahmin etmek için apriori birliktelik kuralı algoritması ile genetik algoritmayı birleştiren melez bir yaklaşım önermişlerdir. Yazarlar bu algoritmanın standart genetik algoritmadan daha hızlı ve daha doğru tahminler ürettiğini raporlamışlardır.
Kasprzyk ve Jaskula	2004	Application of the hybrid genetic-simplex algorithm for deconvolution of electrochemical responses in SDLSV method.	Makale	Yazarlar standart genetik algoritma ile simpleks tepe iniş minimizasyon yöntemlerini birleştirerek melez bir yaklaşım önermişlerdir. Yazarlar algoritmanın iyi sonuçlar verdiğini raporlamışlardır.
Barreto ve arkadaşları	2006	GOLS — Genetic Orthogonal Least Squares Algorithm For Training RBF Networks.	Makale	Yazarlar ortogonal en küçük kareler yöntemi ile genetik algoritmayı birleştiren melez bir yaklaşımı RBF eğitimi için önermişlerdir. Yazarlar yöntemin çok iyi sonuç verdiğini raporlamışlardır.
Wang ve arkadaşları	2008	A resource portfolio planning model using sampling-based stochastic programming and genetic algorithm	Makale	Yazarlar kaynak portföy planlaması için genetik algoritma ile entegre edilmiş iki aşamalı stokastik programlama yaklaşımını önermişlerdir. Yazarlar algoritmanın etkili olduğunu raporlamışlardır.

Yazarlar	Yıl	Yayının Adı	Yayın Türü	Açıklama
Lei	2010	A Genetic Algorithm for Flexible Job Shop Scheduling with Fuzzy Processing Time	Makale	Yazar, bulanık işlem süresi olan esnek bir atölye çizelgeleme problemi için etkili bir ayrıştırma-bütünleştirme genetik algoritması (decomposition-integration genetic algorithm) geliştirmiştir. Yazarlar, yaptıkları testlere göre algoritmanın etkili olduğunu raporlamışlardır.
Gonçalves ve Resende	2011	Biased Random-Key Genetic Algorithms for Combinatorial Optimization	Makale	Yazar çalışmasında taraflı rasgele anahtar genetik algoritmasını önermiştir. Rasgele anahtar genetik algorimalardan farklı olarak çaprazlanan ebeveynlerin biri elit üyelere diğer ise elit olmayan üyelere seçilmektedir.
Dai ve Wang	2012	A Hybrid DNA Based Genetic Algorithm for Parameter Estimation of Dynamic Systems	Makale	Yazarlar, dinamik sistemlerin parametre tahmini için popülasyon güncelleme ve adaptif parametre kapsamı operatörleriyle DNA tabanlı genetik algoritma önermişlerdir. Algoritmada tavlama benzetimi tabanlı seçim operatörü kullanılmaktadır. Yazarlar, test sonuçlarının etkili olduğunu raporlamıştır.
Sun ve Xiong	2013	Real Coded Quantum Genetic Algorithm and its Application	Makale	Yazarlar Kuantum hesaplama ile genetik algoritmayı birleştiren kuantum genetik algoritmasına bir yenilik olarak reel kodlama yapmışlardır. Yazarlar, bu modelin kuantum GA'dan ve standart GA'dan daha iyi sonuç verdiğini raporlamıştır.
Snaselova ve Zboril	2015	Genetic Algorithm Using Theory of Chaos	Makale	Yazarlar kaos teorisine dayanan çaprazlama operatörüyle bir GA önermişlerdir. Makalede, bu algoritmanın iyi sonuçlar verdiği raporlanmıştır.
Antony ve Jayaram	2015	T-GEN: A Tabu Search based Genetic Algorithm for the Automatic Playlist Generation Problem	Makale	Yazarlar genetik algoritmanın küresel arama yeteneği ile tabu arama algoritmasının yerel arama yeteneklerini birleştiren bir model önermişlerdir. Bu modelin basit GA'dan daha iyi sonuç verdiğini raporlanmıştır.
Thao ve arkadaşları	2019	Bridge Critical State Search by Using Quantum Genetic Firefly Algorithm	Makale	Yazarlar flutter analizi için kuantum genetik algoritma ile ateş böceği algoritmasını birleştirerek kuantum genetik ateş böceği algoritmasını önermiştir. Yazarlar, bu algoritmanın çoğu zaman ateş böceği ve genetik algoritmadan daha iyi sonuç verdiğini raporlamıştır.

3.4.2. Genetik Algoritma Türleri


Yazında çok çeşitli tiplerde genetik algoritmalar yer almaktadır. Bunlardan bazıları aşağıda verilmiştir:

- Basit Genetik Algoritmalar (Simple Genetic Algorithms)
- Çok Amaçlı Genetik Algoritmalar (Multi Objective Genetic Algorithms)
- Kuşaksal Genetik Algoritmalar (Generational Genetic Algorithms)
- Kararlı Durum Genetik Algoritmaları (Steady-State Genetic Algorithms)
- Sırasal Genetik Algoritmalar (Sequential Genetic Algorithms)
- Seksüel Genetik Algoritmalar (Sexual Genetic Algorithms)
- Gruplama Genetik Algoritmaları (Grouping Genetic Algorithms)
- Novell Tabanlı Genetik Algoritmalar (Novell Based Genetic Algorithms)
- Lagrangian Genetik Algoritmalar (Lagrangian Genetic Algorithms)
- Mikro Genetik Algoritmalar (Micro Genetic Algorithms)
- Paralel Genetik Algoritmalar (Parallel Genetic Algorithms)
- Dağıtık Genetik Algoritmalar (Distributed Genetic Algorithms)

3.4.3. Genetik Algoritmanın Çalışma Süreci

“Basit bir genetik algoritma beş temel elemandan oluşmakta ve bunların her biri algoritmanın performansını önemli derecede etkilemektedir. Bu temel elemanlar: Çözümlerin temsil mekanizması – kodlama (representation mechanism – Encoding), başlangıç popülasyonu oluşturma yöntemi (initial population construction method), uygunluk veya kalite değerlendirme fonksiyonu (fitness evaluation function), kullanılan genetik operatörler (üreme – reproduction, çaprazlama – crossover, mutasyon – mutation) ve kontrol parametreleridir (Karaboğa, 2004: 79)”. Basit bir genetik algoritmanın evrim süreci Şekil 14’te gösterilmiştir.

Şekil 14: Basit Bir Genetik Algoritmanın Evrimleşme Süreci



3.4.4. Kodlama

Bir problemi genetik algoritma ile çözmeye başladığımızda karşılaşacağımız problemlerden bir tanesi bireylerin (kromozomların) kodlanmasıdır. Bireylerin kodlanması problemin yapısına göre değişmektedir. Literatürde 5 temel kodlama türü vardır: İkili Kodlama (Binary Encoding), Gray Kodlama (Gray Encoding), Permütasyon Kodlama (Permutation Encoding), Değer Kodlama (Value Encoding) ve Ağaç Kodlama (Tree Encoding).

3.4.5. Uygunluk Fonksiyonu

“Çoğu problemde, amacın bazı fayda ya da kazanç fonksiyonlarının $u(x)$ maksimizasyonundan çok, bazı maliyet fonksiyonlarının $g(x)$ minimizasyonu olması oldukça doğaldır. Eğer problem doğal olarak maksimizasyon formunda ise, bu fayda fonksiyonunun tüm x ’ler için pozitif olması garanti edilemez. Sonuçta, sıklıkla doğal amaç fonksiyonunun uygunluk formuna dönüştürülmesi gerekir. Genetik algoritmalarda genel olarak maliyet uygunluğa aşağıdaki gibi dönüştürülür (Goldberg, 1989: 75)”:

$$g(x) < C_{maks} \text{ olduğunda } f(x) = C_{maks} - g(x),$$

Denklem 41

Aksi durumda $f(x) = 0$.

“ C_{maks} değerini seçmek için çeşitli yollar mevcuttur. Bu değer gözlenen en büyük g değeri, mevcut popülasyondaki en büyük g değeri ya da son k nesilin en büyük değeri olarak alınabilir. Belki C_{maks} ’ın popülasyon varyansına bağlı olması çok uygun olabilir (Goldberg, 1989: 76)”.

“Doğal amaç fonksiyonu bir fayda ya da kazanç maksimizasyonu olarak formüle edildiğinde, negatif fayda fonksiyonu değerlerine ilişkin problem yine mevcuttur. Bu problem, aşağıdaki gibi kolayca aşılabılır”:

$$U(x)+C_{\min}>0 \text{ olduğunda } f(x)= U(x)+C_{\min}$$

Denklem 42

Aksi durumda $f(x)=0$.

“ $C_{\min}$ mevcut popülasyonun ya da son k nesilin en kötü u değeri olarak ya da popülasyon varyansının bir fonksiyonu olarak seçilebilir (Goldberg, 1989: 76)”.

“Ceza (Penalty) metodunda, kısıt ihlallerine bir maliyet ya da ceza atanarak kısıtlı bir optimizasyon problemi, kısıtsız problem haline getirilir. Bu maliyetler veya cezalar amaç fonksiyon değerlendirmesinde yer alır (Goldberg, 1989: 85)”.

3.4.6. Başlangıç Popülasyonu

“Araştırma ve uygulama çalışmalarında genetik algoritmaların başlangıç popülasyonunu oluşturmada takip edilen yollar genelde farklıdır. Gerçek mühendislik problemlerinin çözümü için değil de araştırma amacıyla yapılan çalışmalarda genellikle başlangıç popülasyonu rasgele sayı üreticisi kullanılarak oluşturulur. Şayet problemle ilgili başlangıçta bazı çözümler kabaca biliniyorsa başlangıç popülasyonu bu çözümler kullanılarak da oluşturulabilir. Uygulamada tercih edilen yöntem genellikle budur. Çünkü bu yöntem optimal çözüm bulmada zaman açısından tasarruf sağlamaktadır (Karaboğa, 2004: 79-80)”.

“Başlangıç popülasyonu rasgele oluşturulduğunda, genetik algoritmalar tavlama benzetimi algoritmalarından daha az, fakat sezgisel yöntemlerden daha fazla etkilidirler. Eğer başlangıç popülasyonu bir sezgisel tarafından oluşturulursa, genetik algoritmalar tavlama benzetimi algoritmalarından daha etkili olurlar. Ayrıca, diğer arama prosedürleri ile (açgöz rasgele adaptif arama prosedürü - ARAAP, tepe tırmanma, tabu arama, tavlama benzetimi vb.) entegre edilirse, yetenekleri daha da geliştirilebilir (Jones ve Rabelo, 1998: 9)”.

3.4.7. Seçim ve Üreme Operatörleri

Darwin'in evrim teorisine göre, en iyi olanlar kurtulmalı ve yeni nesli oluşturmalıdır. En iyi kromozomları seçmenin birçok yolu vardır. Rulet tekerleği seçimi (Roulette wheel selection), boltzman seçimi (boltzman selection), turnuva seçimi (tournament selection), sıralama seçimi (rank selection), kararlı durum seçimi (steady state selection) bunlardan bazılarıdır (Nabiyev, 2005: 642).

3.4.7.1. Rulet Tekerleği Seçimi (Roulette Wheel Selection)

De Jong 1995'deki çalışmasında basit genetik algoritmanın bir dizi varyasyonunu araştırmıştır. Çalışmasında kullandığı ilk modelde rulet tekerleği seçimini kullanmıştır (Goldberg, 1989: 110). Seçim işlemi, her bireyin uygunluğunun tüm bireylerin toplam uygunluğuna oranına göre yapılmaktadır.

“Bu yöntemde seçilme işlemi bireylerin uygunluk değerlerine göre yapılmaktadır. Fakat uygunluk değeri en büyük olanın seçileceği garanti edilemez, yalnız seçilme şansı daha fazla olacaktır. Bu yöntemde tüm bireylerin uygunluk değerleri bir tabloya yazılır ve toplanır. Sonra uygunluk değerleri, toplama bölünerek bireylerin $[0, 1]$ aralığında seçilme olasılıkları belirlenir (Nabiyev, 2005: 642)”.

3.4.7.2. Sıralama Seçimi (Rank Selection)

“Sıralama seçimi önce popülasyondaki bireyleri uygunluk değerlerine göre sıralamakta ve her kromozomun bu sıralamadaki uygunluğunu belirlemektedir. En kötü birey 1 ve en iyi birey n uygunlukta olacak şekilde yeni uygunluk değerleri hesaplanır (n popülasyon büyüklüğüdür). Sonraki seçim işlemleri rulet tekerleği seçiminde olduğu gibidir (Nabiyev, 2005: 643)”.

3.4.7.3. Uniform Seçim (Uniform Selection)

Hutter tarafından 2002'de önerilen bir seçim yöntemidir. Yöntemin esası şu şekilde açıklanmaktadır: “Eğer mevcut neslin en küçük ve en büyük uygunluğu Min ve Max olarak ifade edilirse, $[Min, Max]$ aralığından uniform dağılıma göre bir f uygunluk değeri seçilir. Seçilen f uygunluk değerine yakın uygunluğa sahip birey seçilir ve eşleşme havuzuna eklenir (Hutter, 2002: 784)”.

3.4.7.4. Turnuva Seçimi (Tournament Selection)

Turnuva seçimi Blickle ve Thierens (1995) tarafından geliştirilmiştir. “Turnuva seçiminde, popülasyondan rasgele seçilen bazı kromozomların en iyisi seçilir. Bu süreç yeni nesil havuzu tamamlanana kadar popülasyon büyüklüğü olan N kadar tekrarlanır (Pakhira ve De, 2007: 76)”.

“Popülasyondan seçilen bireylerin sayısı çoğunlukla ikidir fakat daha geniş turnuva büyüklükleri seçim baskısını arttırabilir. Turnuva seçimi rasgele seçilen birey çiftlerinin en iyisini seçer böylece popülasyon ortalama uygunluğu bir nesilden sonrakine rasgele örneklenen iki birey arasındaki farkın ortalamasının yarısı kadar artar (Thierens ve Goldberg, 1994: 122)”.

3.4.7.5. Kararlı Durum Seçimi (Steady State Selection)

Diğer bir seçim yöntemi de Whitley tarafından 1989 yılında önerilen genitor seçim ya da kararlı durum seçimidir. “Bu yöntemle göre ebeveynlerin büyük kısmı bir sonraki nesile taşınmalıdır. Her nesilde yeni bir döl oluşturmak için birkaç birey seçilir (büyük uygunluk değerine sahip olanlar). Daha sonra düşük uygunluk değerlerine sahip olan bazı kromozomlar atılır ve bunların yerine oluşturulan yeni dölleri getirilir. Popülasyonun geri kalanı değiştirilmeden yeni nesile aktarılır (Whitley, 1989)”.

3.4.8. Çaprazlama ve Mutasyon Operatörleri

Genetik algoritmaların gelişim sürecindeki en önemli operatörleri çaprazlama ve mutasyon operatörleridir.

3.4.8.1. Çaprazlama

“Çaprazlama operatörü, tabii sitemlerde meydana gelen veya genetik çaprazlama olayıyla ortaya çıkan melez (hybrid) yapıların üretilmesine eşdeğer bir özelliği genetik algoritmaya kazandırır. Eşleştirme havuzunda bulunan yapıların birer çifti rasgele seçilir ve çaprazlama operatörü bu iki yapıdan yeni bir yapı meydana getirmek için kullanılır (Karaboğa, 2004: 82)”.

İkili kodlamada kullanılan çaprazlama operatörlerinden bazıları; tek noktalı çaprazlama (one point crossover – 1X), iki noktalı çaprazlama (two point crossover – 2X), n noktalı çaprazlama (n point crossover - NX), düzenli çaprazlama (unifrom

crossover - UX), aritmetik çaprazlama (arithmetic crossover – AX), mantıksal çaprazlama (logical crossover – MX)dir.

Permütasyon kodlama için oldukça fazla çalışma yapılmış olup çok sayıda çaprazlama operatörü geliştirilmiştir. Permütasyon kodlamada temel problem bireylerde aynı değere sahip genlerin olmaması gerekliliğidir. Permütasyon kodlamada yaygın olarak kullanılan bazı çaprazlama operatörleri; tek noktalı çaprazlama (one point crossover -1X), iki noktalı çaprazlama (two point crossover – 2X), düzenli çaprazlama (uniform crossover – UX), pozisyona dayalı çaprazlama (position based crossover – PBX), sıraya dayalı çaprazlama (order based crossover – OBX), kısmî planlı çaprazlama (partially mapped crossover – PMX), çevrim çaprazlama (cycle crossover - CX), sıralı çaprazlama (ordered crossover - OX), doğrusal sıralı çaprazlamadır (linear order crossover – LOX).

Herrera ve diğ. (1998) çalışmalarında gerçel kodlama için çok sayıda çaprazlama operatörünü incelemiş ve karşılaştırmışlardır. Bu çalışmada adı geçen çaprazlama operatörleri (Herrera, Lozano ve Verdegay, 1998): Düzgün çaprazlama – flat Crossover, basit çaprazlama – simple crossover, aritmetiksel çaprazlama – arithmetical crossover, BLX- α çaprazlama, doğrusal çaprazlama – linear crossover, kesikli çaprazlama - discrete crossover, uzatılmış doğrusal çaprazlama - extended linear crossover, uzatılmış orta çaprazlama - extended intermediate crossover, Wright’ın sezgisel çaprazlaması –Wright’s heuristic crossover, doğrusal BGA çaprazlama – linear BGA crossover’dır.

3.4.8.2. Mutasyon Operatörü (Mutation)

“Canlılarda gen rekombinasyonlarının dışındaki diğer nedenlerle ve ani olarak meydana gelen kalıtsal değişimlere mutasyon denir. Mutasyon işlemi esnasında kromozomdaki gen sayısı değişmez sabit kalır. Mutasyon frekansının büyüklüğü genetik algoritmanın performansını etkilemektedir (Engin ve Fırlı, 2002: 38)”.

“Çaprazlama operatörünün her nesile uygulanmasından sonra ilerleyen nesillerde birbirinin aynı gen yapılarına sahip diziler oluşmaktadır. Bu durumu ortadan kaldırmak için değişim (mutasyon) operatörü uygulanır. Bu operatörün amacı birbirinin tekrarı olan ve çeşitliliğin azaldığı durumda, aynı kromozomdaki genlerin yerinin değiştirilmesidir (Biroğul, 2005: 3)”.

İkili ve gray kodlamada tek noktada mutasyon veya çok noktada mutasyon operatörleri vardır. Rastgele seçilen bir veya çok sayıda genin değeri 0 ise 1, 1 ise 0 şeklinde değiştirilir.

Permütasyon kodlamada önemli olan nokta genlerin aynı değere sahip olmamasıdır. Bu nedenle permütasyon kodlama için ikili kodlamada kullanılan mutasyon operatörleri uygun değildir. Bu operatörler kullanılırsa bir tamir operatörüne ihtiyaç duyulacaktır. Permütasyon kodlama için geliştirilen operatörlerin bir kısmı bu tür bir tamir fonksiyonunu da yerine getirmektedir.

Literatürde görülen permütasyon kodlama için geliştirilmiş mutasyon operatörlerinden bazıları: İki bitişik iş takası (two operations adjacent swap), üç bitişik iş takası (three operations adjacent swap), iki rasgele iş takası (two operations random swap), üç rasgele iş takası (three operations random swap), ters çevirme mutasyonu (inverse mutation), iş kaydırma mutasyonu (shift operation mutation), orta ters çevirme mutasyonu (centre inverse mutation), gelişmiş rasgele iki iş takası (enhanced two operations random swap) dır.

Gerçel kodlama çok çeşitli mutasyon operatörleri geliştirilmiştir. Genelde mutasyon işleminde geçerli aralıktan rasgele bir sayının seçilmesi ya da matematiksel çeşitli yöntemler kullanılmaktadır.

Herrera ve diğerleri (1998) gerçel kodlama için kullanılan operatörlerden bazılarını çalışmalarında göstermişler ve davranışsal analizini yapmışlardır (Herrera vd., 1998). Bunlar: rasgele mutasyon -random mutation, düzensiz mutasyon - non-uniform mutation, Mühlenbein'in mutasyonu - Mühlenbein's mutation, kesikli modal mutasyon - discrete modal mutation, sürekli modal mutasyon - continuous modal mutation'dır.

3.4.9. Erken Yakınsama Problemi ve Ölçekleme

“Bazı bireylerin uygunluğunun popülasyon ortalamasından çok yüksek olduğu durumlarda, rulet tekerleği seçim yönteminde popülasyonun bu üyeleri diğer üyelerden daha sık seçilecektir. Bu nedenle, birkaç nesil sonra eşleşme havuzu bu bireylerle dolar. Eğer bu bireyler küresel maksimuma değil yerel maksimuma yakınsa, genetik algoritma mutasyon ya da hiper-mutasyon yardımı olmazsa yerel maksimuma takılacaktır. Bu durum erken yakınsama (premature convergence) olarak bilinir. Rulet tekerleği seçiminde bir diğer problem tıkanıklıktır (stagnation). Bu problem genellikle

çalışmanın sonlarına doğru meydana gelir. Eğer tüm bireyler benzer uygunluğa sahipse, rulet tekerleği seçimi düşük seçim baskısı uygular ve en iyi bireye hemen hemen en kötü birey kadar seçilme şansı tanır. Bu iki problem uygunluk ölçekleme teknikleri kullanılarak çözülebilir (Murphy, 2003: 23)’’.

Ölçekleme yöntemlerinin iki amacı vardır:

1. Kromozomların göreceli uygunluk dereceleri arasında makul bir farklılığın korunmasını sağlayarak algoritmanın tıkanıklıktan kurtarılması,
2. Popülasyonun süper kromozomlar tarafından çabuk ele geçirilmesini önleyerek algoritmanın erken yakınsamadan kurtarılmasını sağlamak.

Doğrusal ölçekleme (linear scaling), dinamik doğrusal ölçekleme (dynamic linear scaling), sigma budama (sigma truncation), üs kuralı ölçekleme (power law scaling), ölçekleme penceresi (scaling window), boltzman seçimi, logaritmik ölçekleme ve normalizasyon (normalizing) yöntemleri bu amaçlar için oluşturulmuştur.

3.4.10. Seçkinlik (Elitizm) Kavramı

Çaprazlama ve mutasyon işlemleri neticesinde popülasyondaki en iyi bireyin kaybedilmesi mümkün olabilir. “Seçkinlik, önce en iyi kromozomu (ya da birkaç en iyi kromozomu) yeni nesile kopyalar. Geri kalan bireylere ise çaprazlama ve mutasyon uygulanır. Seçkinlik, bulunan en iyi sonucun kaybını önlediği için, genetik algoritmanın performansını oldukça hızlı bir şekilde artırır (Nabiyev, 2005: 644)’’.

3.4.11. Parametre Optimizasyonu

Çaprazlama, mutasyon ve yeniden üreme operatörleri gibi, algoritmanın kontrol parametreleri değerlerinin seçimi de algoritmanın performansı üzerinde oldukça etkilidir. Basit bir genetik algoritmanın temel kontrol parametreleri şunlardır: Popülasyon büyüklüğü, çaprazlama ve mutasyon oranları.

“Popülasyon büyüklüğü için seçilen değer, algoritmanın performansını iki şekilde etkilemektedir. Birincisi, popülasyon büyüklüğünün aşırı küçülmesi araştırma uzayının yetersiz örneklenmesine sebep olacağından kontrollü ıraksamayı sağlamak zorlaşacak ve araştırma belirli bir alt optimal noktaya doğru sürüklenecektir. İkincisi,

popülasyon için aşırı yüksek değer seçildiğinde bir nesillik gelişim oldukça uzun süreye ihtiyaç duymaktadır. Bu yüzden popülasyon büyüklüğü için uygun bir değer belirlenmelidir (Nabiyev, 2005: 641)’’.

Popülasyon büyüklüğü için De Jong 1975’deki çalışmasında 50-100 değerlerini önerirken, Schaffer ve arkadaşları 1989’daki çalışmalarında 20-20 değerini, Grefenstette ise 1986 yılındaki çalışmasında 30 değerini önermiştir. Goldberg 1985’deki çalışmasında ikili kodlama için popülasyon büyüklüğünün $1,65 \times 2^{0,2 \times \text{kromozom uzunluğu}}$ formülü ile hesaplanmasını önermiştir.

“Çaprazlama oranı, yeni bireylerin üretiminde yapılara (popülasyonun bireyleri) uygulanacak çaprazlama operatörünün frekansını belirlemek amacıyla kullanılan parametredir. Düşük çaprazlama oranı yeni kuşağa çok az sayıda yeni yapının girmesine sebep olmaktadır. Dolayısıyla üreme operatörü algoritmada aşırı etkili bir operatör haline gelmekte ve araştırmanın yakınsama hızı düşmektedir. Yüksek çaprazlama oranı araştırma uzayının çok hızlı bir şekilde araştırılmasına sebep olmaktadır. Ama oran aşırı yüksek ise çaprazlama operatörü daha iyi yapıları üretmeden ve kuvvetli olan yapılar çok hızlı olarak bozulduğundan algoritmanın performansı düşmektedir (Karaboğa, 2004: 85)’’.

Mutasyon operatörünün frekansı, etkili bir genetik algoritma tasarlamak için çok iyi kontrol edilmelidir. Mutasyon operasyonu, araştırma sahasına yeni bölgelerin girmesini sağlar. Yüksek mutasyon oranı, araştırmaya aşırı bir rasgelelik kazandıracak ve araştırmayı çok hızlı olarak ıraksatacaktır. Başka bir deyişle, popülasyonun gelişmesine değil tahribatına sebep olacaktır. Bu durumun tersine, çok düşük mutasyon oranının kullanılması ıraksamayı aşırı düşürecek ve araştırma uzayının tamamen araştırılmasını engelleyecektir. Dolayısıyla, algoritmanın alt optimal çözüm bulmasına sebep olacaktır (Karaboğa, 2004, s. 86)’’.

De Jong çaprazlama oranının % 60 olması gerektiğini savunurken, Schaffer % 75 ile % 95 arasında bir değeri, Grefenstette ise % 95 değerini önermiştir. Mutasyon oranı için De Jong % 0,1, Schaffer % 0,5- %1 arasında bir değer, Grefenstette %1 değerini önermiştir (Karaboğa, 2004: 91).

Genetik algoritma parametrelerinin çalışma esnasında değiştirilmesini sağlayan çeşitli adaptasyon önerileri geliştirilmiştir (Davis, 1989; Whitley ve Hanson, 1989; Fogarty, 1989). Karaboğa 2004’deki kitabında üç farklı mutasyon oranı stratejisi önermiştir. Bu stratejilerin ilkinde, algoritma çözümü araştırırken gelişim sağlanamadığında mutasyon oranını değiştirmeye başlamaktır. Çözümün

geliştirilemediği adımlarda mutasyon oranı kademeli olarak arttırılmaktadır. İkinci stratejide mutasyon oranı kromozomun uygunluk değerine göre hesaplanmaktadır. Bunun için kullanılan formül denklem 43’de gösterilmiştir (Karaboğa, 2004: 92).

$$MO(i) = (1 - uygunluk(i)) \times (MO_{max} - MO_{min}) + MO_{min} \quad \text{Denklem 43}$$

Bu formülde MO (i), i. Kromozom için hesaplanan mutasyon oranını, MO_{max} en yüksek mutasyon oranını, MO_{min} ise en düşük mutasyon oranını ifade eder. Uygunluk (i) ise i. Kromozom için hesaplanmış olan uygunluk fonksiyonu değeridir. Karaboğa’nın önerdiği üçüncü stratejide ise 2. Strateji uygulanarak hesaplanan değer her kromozom geninin pozisyonuna göre denklem 44’deki gibi hesaplanır (Karaboğa, 2004: 94).

$$\begin{cases} MO(ik) = \left(\frac{L-k}{L}\right) \times MO(i) & g \leq (maks\ g)/2 \\ MO(ik) = \left(\frac{k}{L}\right) \times MO(i) & g > (maks\ g)/2 \end{cases} \quad \text{Denklem 44}$$

Denklem 44’de MO (ik) i. kromozom k. geni için hesaplanan mutasyon oranıdır. L kromozom uzunluğunu, k gen konumunu, g jenerasyon sayısını, maks g ise üretilecek jenerasyon sayısını ifade eder (Karaboğa, 2004: 96-97).

3.4.12. Melez Yaklaşımlar

Genetik algoritma ile diğer bazı yöntem ve algoritmaların birleştirilmesi sonucunda çeşitli melez yaklaşımlar ortaya çıkmıştır. Son yıllarda yapay zeka tekniklerinin beraber kullanımı veya türeve dayalı tekniklerle genetik algoritmaların birleştirildiği çalışmalara sıklıkla rastlanmaktadır.

Yiğit ve Günel 2016 yılındaki çalışmalarında Konveks-Genetik-Taguchi Algoritması adını verdikleri, Konveks optimizasyon, Genetik Algoritma ve Taguchi Yöntemini birlikte kullanan bir melez yaklaşım geliştirmişlerdir. Bu algoritma ile doğrusal anten dizisinde istenilen yan demet seviyesi ve yarım güç demet genişliğini elde etmek için kullanılmıştır (Yiğit ve Günel, 2016).

Şeker 2013’te yazdığı doktora tezinde, süreç planlama ve çizelgeleme entegrasyonu için yapay sinir ağları ile genetik algoritmayı birleştiren melez bir yaklaşım geliştirmiştir (Şeker, 2013).

Demirel ve arkadaşları 2011'deki makalelerinde bütünleşik bir lojistik ağı tasarımı için kapasite kısıtlı, çok aşamalı, çok ürünlü bir karma tamsayılı doğrusal programlama modeli geliştirilmiştir. Yazarlar, modelin karmaşık yapısından dolayı, sezgisel yöntem ile doğrusal programlamayı birlikte kullanan genetik algoritma tabanlı melez bir çözüm yöntemi geliştirmişlerdir (Demirel vd., 2011).

Yücenur ve Demirel 2011 yılındaki makalelerinde, Lojistik sektöründe çok depolu araç rotalama probleminin çözümü için genetik algoritmanın (GA) ve karınca kolonisi optimizasyonunun (KKO) bir arada kullanılmasıyla oluşturulan melez meta sezgisel bir yapı önermişlerdir (Yücenur ve Demirel, 2011).

3.5. GELİŞTİRİLEN ALGORİTMİK YAKLAŞIM

3.5.1. Hedef Programlama Modeli ve Amaç Denklem

Bu bölümde benzer çalışmalarda (Alp, 2008; Uludağ, 2010; Deri, 2012) olduğu gibi optimum sefer sıklığını belirlemek üzere doğrusal hedef programlama modeli kurulmuş ve bu modele dayalı bir çözüm yaklaşımı geliştirilmiştir.

Sistem Kısıtları

Hatlardaki otobüslerle yeteri sayıda sefer düzenlenmeli ve her hattaki talep karşılanmalıdır. Bunun için denklem 45'deki sistem kısıtı düzenlenmiştir.

$X_1, X_2, \dots, X_i$: Hatlar için sefer sıklık değerlerini,

$K_1, K_2, \dots, K_i$: Her hatta kullanılan otobüs tipinin kapasite değerlerini

$T_1, T_2, \dots, T_i$: Her hatta bulunan yolcu talep değerlerini göstermek üzere,

$$X_i \times K_i \geq T_i$$

Denklem 45

bağıntısı ile ifade edilebilir.

Hedef Kısıtları

Modelin hedef kısıtları, süre ve kapasite kısıtı olarak belirlenmiştir. Süre kısıtları düzenlenirken, her saat için 60 dakikalık süreçte filoda çalışan otobüs sayısının, her hattın bir seferi için gerekli olan süre ve bu hattaki sefer sıklık değeri ile

karşılanabilmesi esas alınmıştır. Literatürde, benzer çalışmalarda bu durum söz konusudur (Alp, 2008; Uludağ, 2010; Deri, 2012).

Otobüs Kısıtı:

$$\sum_{i=1}^{h_K} \frac{s_i}{S_i} \times X_i + d_K^+ + d_K^- = B_K; \sum_{i=1}^{h_S} \frac{s_i}{S_i} \times X_i + d_S^+ + d_S^- = B_S \text{ Denklem 46}$$

olup,

s_i : Her bir otobüs hattı için ortalama sefer süresi

S_i : Planlamaya esas olan süre

X_i : i hattı için optimum sefer sıklık değeri

B_K : Mevcut körüklü otobüs sayısı

B_S : Mevcut solo otobüs sayısı

d_K^+ : Körüklü otobüsler için fazla süre; d_K^- : Körüklü otobüsler için eksik süreyi

d_S^+ : Solo otobüsler için fazla süre; d_S^- : Solo otobüsler için eksik süreyi

ifade eder.

Kapasite Kısıtı:

$$\sum_{i=1}^m K_i \times X_i + d_1^+ + d_1^- = \sum_{i=1}^m T_i \text{ Denklem 47}$$

d_1^+ : Fazla kapasiteyi; d_1^- : eksik kapasiteyi ifade eder.

Amaç Denklem

Modelde amaç fonksiyonu oluşturulurken, süre ve kapasite hedef kısıtları eşit öncelikli olarak kabul edilmiştir. Oluşturulan amaç fonksiyonu bu iki kısıta ait negatif sapma toplamının minimize edilmesi şeklinde olup aşağıda gösterilmiştir.

$$\text{Min } Z = d_1^+ + d_1^- + d_K^+ + d_K^- + d_S^+ + d_S^- \text{ Denklem 48}$$

Modele yolcuların durakta bekleme zamanının eklenmesi


Yolcuların durakta bekleme sürelerinin dağılımına ilişkin çeşitli çalışmalar mevcuttur. Bazı çalışmalar bekleme süresini, toplu taşıma zaman çizelgesine dayalı biniş zamanı seçiminin bir parçası olarak modellemiştir (Nielsen, 2004; Nielsen ve

Frederiksen, 2006; Gentile vd., 2016; Nuzzolo vd., 2001). Ancak, gerçek yolcuların durağa gelişi, bu nedenle gerçek yolcu bekleme süreleri, yüksek hizmet frekansı olduğunda zaman çizelgesinden etkilenmemektedir (Nuzzolo vd., 2001; Nuzzolo vd. 2012; Nuzzolo vd., 2015). Bununla birlikte, her iki model de, gerçek yolcu varış desenlerini ve bekleme süresi dağılımlarını doğru bir şekilde hesaba katmamaktadır, bu nedenle yolcu bekleme süresi modellerini tahmin etmek için basit bir yaklaşıma ihtiyaç duyulmaktadır (Ingvardson vd., 2018: 294).

Zaman çizelgesini dikkate almayan yolcuların Poisson varış süreçlerine göre vardıkları varsayılmaktadır. Bu nedenle, yolcular istasyonlara rastgele gelirler ve bekleme süreleri, çeşitli çalışmalarda önerildiği gibi uniform dağılıma uygundur (Fu vd., 2012; Luethi vd., 2007; Nielsen, 2000; Nökel ve Wekeck, 2009; Schmöcker vd., 2011).

Zaman çizelgesini dikkate alanlar ise bekleme sürelerini minimize etmek için kalkış zamanına yakın olarak farklı zamanlarda geleceklerdir. Bekleme süresi bu nedenle uniform değil bir beta dağılımı ile açıklanabilecektir. Beta dağılımı üç özelliğe sahiptir: (1) Seferler arası süre tarafından sınırlandırılan bekleme zamanı toplu taşıma araçlarının operasyonel karakteristiklerine uyan bir aralıkta sınırlıdır. (2) Beta dağılımı zaman çizelgesini bilen yolcuların karakteristiklerini işleyebilir. Yani, yolcuların hedefledikleri otobüse yetişebilmek için bir tampon zaman ekledikleri varsayılır (Fonzone vd., 2015; Frumin ve Zhao, 2012). Şekil 15’de görüldüğü gibi tampon süresi yolcular ve servis sıklıklarına göre değiştiğinden, durağa varış yoğunluğunun kalkış saatinden birkaç dakika önce en yüksek olduğu ve bir sonraki kalkış saatine doğru azalacağı varsayılır. Beta bileşeninin şekil parametreleri (α ve β), hizmet frekansları arasında değişebilen çarpıklıklığı tanımladıkları için bunu belirgin şekilde modelleyebilir. (3) Uniform dağılım beta dağılımının özel bir türüdür. Rastgele yolcu gelişleri ile zaman çizelgesine bağlı yolcu gelişleri arasında güçlü bir ilişki vardır (Ingvardson vd., 2018: 295).

Şekil 15: $\zeta=0.67$, $\alpha=1.5$ ve $\beta=4$ Karma Dağılımın Görünümü



Marguier ve Ceder 1984'deki makalelerinde ortalama bekleme zamanı ile sefer arası süre arasındaki ilişkiyi incelemişlerdir. Yazarlar bu ilişkiyi aşağıdaki formülle göstermişlerdir (Marguier ve Ceder, 1984: 209):

$$E(W) = (E(H^2)) / 2E(H) = E(H) / 2 [1 + (\text{Var}(H) / E^2(H))]$$

Denklem 49

$E(W)$: Ortalama bekleme zamanı

$E(H)$: Ortalama seferler arası süre

$\text{Var}(H)$: Seferler arası sürenin varyansı

Holroyd ve Scraggs (1966) aşağıdaki özel durumlardan bahsetmektedir:


(1) Düzenli otobüs varışları: $\text{Var } H = 0$, yani $E(W) = 1 / 2 E(H)$

(2) Bir grup (düzenli) varışlar (n otobüs): $\text{Var } H = (n - 1) E^2(H)$, yani $E(W) = 1/2 n E(H)$

(3) Poisson otobüs varışları: $\text{Var } H = E^2(H)$, yani $E(W) = E(H)$

Seferlerin hangi dağılıma uygun olduğunu belirlemek üzere seferler arası süreler hesaplanmış ve Matlab R2014 yazılımının “Distribution Fitting” uygulaması ile incelenmiş ve poisson dağılımına uygun olduğu görülmüştür. Analiz sonuçları Şekil 16’da gösterilmiştir.

Şekil 16: Otobüs Sefer Sürelerinin Dağılımı



Bu nedenle Holroyd ve Scraggs'ın 2. varsayımına göre ortalama durakta bekleme süresi ortalama seferler arası süreye eşit kabul edilmiştir.

$$\text{Seferler Arası Süre} : E(H) = \frac{S_i}{X_i}$$

$$\text{Ortalama Bekleme Süresi: } E(W) = E(H) = \frac{S_i}{X_i}$$

Ortalama bekleme süresi de dikkate alındığında amaç denklem aşağıdaki gibi olacaktır.

$$\text{Min } Z = d_1^+ + d_1^- + d_K^+ + d_K^- + d_S^+ + d_S^- + \frac{S_i}{X_i} \quad \text{Denklem 50}$$


3.5.2. Önerilen Yöntem

Sefer sıklığı optimizasyonunda hedef programlama amaç denklemine dayalı bir yöntem uygulanmıştır. Bu yöntemde sefer sıklığı değişkeni için alt ve üst sınırlar belirlenerek algoritma çalışmasına başlamaktadır. Aşağıdaki formüle göre aday sefer sıklığı belirleniyor.

$$X = \text{alt sınır} + \text{tamsayı} \left(\frac{\text{üst sınır} - \text{alt sınır}}{2} \right)$$

Bu formüle göre hesaplanan sefer sıklığı (x), bu değerin bir öncesi ($x-1$) ve bir sonrası ($x+1$) için amaç denklem değerleri (Z : x için, Z_0 : $x-1$ için, Z_s ise $x+1$ için amaç denklem değeri) hesaplanır. Eğer Z değeri Z_0 ve Z_s 'den büyük ise Z optimum amaç değeri olup X optimum sefer sıklığı olacaktır. Eğer Z değeri Z_0 'den büyük Z_s 'den küçükse alt sınır $x+1$ olarak değiştirilir. Eğer Z değeri Z_0 'den küçükse, Z değeri Z_s 'den büyükse üst limit $x-1$ olarak aksi durumda ise alt sınır = $x+1$ olarak değiştirilir. Böylece alt ve üst sınırlar değiştirilmeye devam ederek optimum sonuca yaklaşılr. Eğer alt sınır ile üst sınır aynı ise optimum sefer sıklığı bu değer kabul edilir. Eğer alt sınır ile üst sınır arasındaki fark 1 ise, alt sınır ve üst sınır için amaç denklem değerleri (Z_1 , Z_2) hesaplanır. Eğer $Z_1 > Z_2$ ise optimum sefer sıklığı alt sınırdır, aksi durumda ise optimum sefer sıklığı üst sınır kabul edilir. Algoritmanın akış şeması Şekil 16'da gösterilmiştir.

Şekil 17: Sefer Sıklığı Optimizasyonu için Önerilen Algoritmanın Akış Şeması



3.5.3. Yöntem İçin Uygulama Örneği

Yöntemin çalışması adım adım Tablo 5’de gösterilmiştir. Bu problem için 1 dakikadan küçük zaman aralıklarıyla otobüs görevlendirilemeyeceği varsayıldığı için sefer sıklığı 1 ile 60 arasında bir değer alabilir.

Tablo 5: Sefer Sıklığı Optimizasyon Algoritmasının Adım Adım İşleyişi

K_K=150; K_S=100; T_i=793; s_i=35 dakika; S_i=60 dakika; B_K=5 körüklü otobüs; B_S= 2 solo otobüs												
Adım	Alt Sınır	Üst Sınır		X_i	Bekleme	d1p	d1n	dkp	dkn	dsp	dsn	Z
1	1	60	z _ö	29	2,07	3142,71	0,00	0,00	7,08	0,00	6,29	3.158,2
			z	30	2,00	3278,43	0,00	0,00	7,50	0,00	6,57	3.294,5
			z _s	31	1,94	3414,14	0,00	0,00	7,92	0,00	6,86	3.430,9
2	1	29	z _ö	14	4,29	1107,00	0,00	0,00	0,83	0,00	2,00	1.114,1
			z	15	4,00	1242,71	0,00	0,00	1,25	0,00	2,29	1.250,3
			z _s	16	3,75	1378,43	0,00	0,00	1,67	0,00	2,57	1.386,4
3	1	14	z _ö	6	10,00	21,29	0,00	2,50	0,00	0,29	0,00	34,1
			z	7	8,57	157,00	0,00	2,08	0,00	0,00	0,00	167,7
			z _s	8	7,50	292,71	0,00	1,67	0,00	0,00	0,29	302,2
4	1	6	z _ö	2	30,00	0,00	521,57	4,17	0,00	1,43	0,00	557,2
			z	3	20,00	0,00	385,86	3,75	0,00	1,14	0,00	410,8
			z _s	4	15,00	0,00	250,14	3,33	0,00	0,86	0,00	269,3
5	4	6	z _ö	4	15,00	0,00	250,14	3,33	0,00	0,86	0,00	269,3
			z	5	12,00	0,00	114,43	2,92	0,00	0,57	0,00	129,9
			z _s	6	10,00	21,29	0,00	2,50	0,00	0,29	0,00	34,1
6	6	6	z	6	10	21,29	0,00	2,50	0,00	0,29	0,00	34,1

Tablodaki K_K ve K_S değerleri körüklü ve solo otobüsler için kapasiteyi ifade etmektedir. Yine tablodaki $d_1^+, d_1^-, d_K^+, d_K^-, d_S^+, d_S^-$ değerleri hedeflerden sapmaları göstermektedir. Amaç denklem ($Min Z = d_1^+ + d_1^- + d_K^+ + d_K^- + d_S^+ + d_S^- + \text{Bekleme}$) bu sapmaları ve bekleme süresini içermektedir.

İlk adımda amaç denklem değerinin sefer sıklığı 30’dan küçük olduğunda iyileştiğini görmekteyiz. Bu nedenle üst sınır 29 olarak değiştirilir. İkinci adımda da en küçük z değeri 14 için hesaplanmıştır. Yani optimum sefer sıklığı 15’den daha küçüktür. Üst sınır 14 olarak değiştirilir. Üçüncü adımda en küçük z değeri 6 için hesaplanmıştır. Optimum sefer sıklığı 7’den daha küçüktür. Bu nedenle üst sınır 6 olarak değiştirilir. Dördüncü adımda en küçük z değeri 4 için hesaplanmıştır. Optimum sefer sıklığı 3’den daha büyüktür. Bu nedenle alt sınır 4 olarak değiştirilir. Beşinci adımda en iyi amaç denklem değeri sefer sıklığının 5 olduğunda ortaya çıkmaktadır. Bu adımda z’nin z_ö ve z_s’den daha küçük olduğu görüldüğünden optimum çözüme

ulaşıldığı anlaşılr. Optimum sefer sıklığı 5’dir ve bu sefer sıklığı için amaç denklem değeri 57,0’dır. Bu çözümde az da olsa bir kapasite eksiği körüklü ve solo otobüsler içinse atıl zaman oluşumu görülmektedir. Bekleme süresi bakımından da daha iyi sonuçlar elde edilebilir. Bekleme süresi ve negatif sapmaların daha önemli olduğu görülmüştür. Bu nedenle negatif sapmalar için 100 ve bekleme süresi için 1 ağırlık katsayısı, pozitif sapmalar içinse 0,01 ağırlık katsayısı kullanılabilir.

Bu durumda amaç denklem aşağıdaki gibi olacaktır:

$$\text{Min } Z = 0,01. (d_1^+ + d_K^+ + d_S^+) + 100. (d_1^- + d_K^- + d_S^-) + 1,2 \cdot \frac{S_i}{x_i}$$

Ağırlıklı amaç denkleme göre sonuç aşağıdaki Tablo 6’da görülmektedir.

Tablo 6: Ağırlık Katsayıları Uygulandığında Algoritmanın İşleyişi

K _K =150; K _S =100; T _i =793; s _i =35 dakika; S _i =60 dakika; B _K =5 körüklü otobüs; B _S = 2 solo otobüs												
Adım	Alt Sınır	Üst Sınır		X _i	Bekleme	d _{1p}	d _{1n}	d _{Kp}	d _{Kn}	d _{Sp}	d _{Sn}	z
1	1	60	z _ö	29	2,07	3142,71	0,00	0,00	7,08	0,00	6,29	1.370,8
			z	30	2,00	3278,43	0,00	0,00	7,50	0,00	6,57	1.442,3
			z _s	31	1,94	3414,14	0,00	0,00	7,92	0,00	6,86	1.513,8
2	1	29	z _ö	14	4,29	1107,00	0,00	0,00	0,83	0,00	2,00	299,5
			z	15	4,00	1242,71	0,00	0,00	1,25	0,00	2,29	370,8
			z _s	16	3,75	1378,43	0,00	0,00	1,67	0,00	2,57	442,1
3	1	14	z _ö	6	10,00	21,29	0,00	2,50	0,00	0,29	0,00	12,2
			z	7	8,57	157,00	0,00	2,08	0,00	0,00	0,00	11,9
			z _s	8	7,50	292,71	0,00	1,67	0,00	0,00	0,29	40,5

Ağırlıklandırma ile amaç denklemlerin hesaplanması durumunda optimum sefer sıklığı 5 değil 6 olarak hesaplanmıştır. Amaç denklemin optimum sonucu 82,5’dir. Bu yöntemde birinci öncelikli olarak negatif sapmalar, ikinci öncelikli olarak bekleme süreleri ve son öncelikte ise pozitif sapmalar dikkate alınmaktadır. Ağırlıklandırmadan ve ağırlıklandırılarak hesaplanan Z değerlerine göre optimum sefer sıklıkları ve diğer istatistikler Tablo 7’de gösterilmiştir.

Tablo 7: Ağırlıklı ve Ağırlıksız Modellerin Sonuçlarının Karşılaştırılması

Model	X _i	Bekleme	d ₁ ⁺	d ₁ ⁻	d _K ⁺	d _K ⁻	d _S ⁺	d _S ⁻	Z
Ağırlıksız	6	10	21,29	0,00	2,50	0,00	0,29	0,00	34,1
Ağırlıklı	7	8,57	157,00	0,00	2,08	0,00	0,00	0,00	11,9

Tablo 7’de görüldüğü gibi bütün negatif sapma değerleri sıfırdır. Tüketici talebinin karşılanması sunulan hizmet kalitesi bakımından bu oldukça önem

taşımaktadır. İkinci öncelik olarak hizmet kalitesi algısını etkileyen bekleme süresi seçildiği için ağırlıklandırma ile elde edilen optimum sefer sıklıkları daha iyi sonuç vermektedir. Çünkü, bekleme süresi nedeniyle müşteri memnuniyetsizliği olacağına atıl kapasite ve atıl zaman olması daha iyi olacaktır.



DÖRDÜNCÜ BÖLÜM

ESHOT GENEL MÜDÜRLÜĞÜ UYGULAMASI

Çalışmanın bu bölümünde; ele alınan problemin tanımı, araştırmanın amacı, kapsamı, varsayımları, sınırlılıkları ve yöntemleri açıklanmıştır. Verilerin elde edilişi, prototip uygulamanın geliştirilmesi ve algortimanın veri setine uygulanması ve uygulama sonucunda elde edilen bulgular sunulmuştur.

İzmir Belediyesi kent içinde birbirinden ayrı olarak faaliyet gösteren otobüs, tramvay, elektrik su ve hava gazı işletmelerini birleştirerek üniter bir yapı oluşturmak istemiştir. Bu amaçla, İzmir Tramvay ve Elektrik Türk Şirketi 27 Temmuz 1943 tarihinde 4483 sayılı yasayla katma değer bütçeli bir idare şeklinde yönetilmek üzere İzmir Belediyesi'ne bağlı bir işletme olarak kurulmuştur. 1945 yılından itibaren ise daha önce Belediyeye devredilen, Tramvay ve Elektrik İşletmesi, İzmir Suları İşletmesi ve Havagazı İşletmesini kapsayan Belediyeye bağlı mülhak bütçeli bir Umum Müdürlük (İzmir Elektrik, Su, Havagazı, Otobüs ve Trolleybüs - ESHOT Genel Müdürlüğü) kurulmuştur (ESHOT Genel Müdürlüğü, 2009).

ESHOT Genel Müdürlüğü, Elektrik, Su, Havagazı ve Toplu Ulaşım gibi geniş bir yelpazede, İzmir kentine hizmet vermek üzere kurulmuş, İzmir Büyükşehir Belediyesine bağlı, mülhak bütçeli, bünyesinden Türk Elektrik Kurumu - TEK ve İzmir Su ve Kanalizasyon İdaresi - İZSU gibi iki ayrı kurum çıkarmış, deneyimli, bilgi birikimli, köklü bir kuruluştur (ESHOT, 2017).

4.1. ARAŞTIRMANIN AMACI

Bu çalışmada ESHOT Genel Müdürlüğü Ulaşım Planlama Daire Başkanlığı'ndan alınan 30 günlük akıllı kart biniş verisinden faydalanarak iniş duraklarının tahmin edilmesini sağlayan bir algoritma geliştirmek amaçlanmıştır. Her hat için biniş ve iniş durakları bilgilerinden yararlanarak başlangıç-varış (BV) matrislerini oluşturan bir algoritma geliştirmek birinci amaç iken BV matris verilerinden maksimum hat taleplerini hesaplayan bir algoritma geliştirmek araştırmanın ikinci amacıdır. 30 günlük verilerden yararlanarak gelecekteki maksimum hat taleplerini her servis zamanı için tahmin etmek üzere çok katmanlı algılayıcı tipinde ileri beslemeli bir yapay sinir ağı geliştirmek ve hat ile ilişkili bilgiler

yardımla optimum sefer sıklığını genetik algoritma yardımla hesaplayan bir yazılım geliştirmek amaçlanmıştır.

4.2. ARAŞTIRMANIN KAPSAMI

Araştırma ESHOT Genel Müdürlüğü Ulaşım Planlama Daire Başkanlığı veri tabanında toplanan 2015 ve 2017 yılına ilişkin akıllı kart hareketlerini kapsamaktadır. ESHOT Genel Müdürlüğü 2015 yılı verilerinden 15 günlük veri ile 2017 yılı verilerinden 30 günlük bir kısmını tarafımıza vermiştir. 2015 yılı verileri “Otogar – Konak” Hattı için prototip uygulama geliştirmek amacıyla kullanılmıştır. 2017 yılı verileri Konak bağlantılı en yoğun 10 hat için algoritmanın test edilmesi amacıyla kullanılmıştır.

4.3. ARAŞTIRMANIN VARSAYIMLARI

Araştırmada akıllı kart kullanıcılarının yoğunluğunun düzenli biniş ve iniş hareketleri gerçekleştirdiği varsayılmıştır. Akıllı kart kullanıcısının aktarma yapması durumunda, aktarma hattındaki biniş durağına önceki binişin gerçekleştiği hattaki en yakın durakta iniş yapacağı varsayılmaktadır. Sabah ilk iniş durağının akşamki son biniş durağı veya ilgili hatta bu durağa en yakın durak olacağı varsayılmaktadır. Yolcuların geçmişteki davranışlarını tekrarlayacakları varsayılarak gelecek öngörüsünde geçmişteki maksimum hat talepleri dikkate alınmıştır.

4.4. ARAŞTIRMANIN SINIRLILIKLARI

Araştırmadaki en önemli sınırlılık ESHOT Genel Müdürlüğü’nden elde edilen verilerin sadece 45 günlük veriyi içermesidir. 45 günlük veri yerine 6 aylık veri olması durumunda gelecek için daha iyi tahminler yapılabileceği düşünülmüştür.

Araştırmanın ikinci önemli sınırlılığı çok büyük miktarda verilerle işlem yapma kapasitesine sahip olan güçlü bir sunucunun bulunmamasıdır. Veriler Intel i7-6700HQ 2.60 Ghz işlemcili 16 GB RAM içeren bir dizüstü bilgisayar yardımla işlenmiştir. Bu nedenle yapılan işlemler çok uzun zaman almaktadır. Bu da algoritmayı geliştirmek için ciddi miktarda bir zaman sınırlılığı ortaya çıkarmaktadır.

4.5. ARAŞTIRMANIN YÖNTEMLERİ

Araştırmada öncelikle akıllı kart kullanıcılarının biniş verilerinden zamansal-mekansal kullanım modellerinin tespiti için veri madenciliği yöntemlerinden K-ortalama kümeleme algoritması kullanılmıştır. Daha sonra Trépanier ve arkadaşlarının önerdikleri yolculuk zincirleme algoritması ile Diker'in önerdiği rastgele atama tahmin yöntemi Embarcadero Delphi Programlama dili ile kodlanmış ve biniş duraklarından iniş duraklarını tahmin eden bir yazılım geliştirilmiştir. Her hatta meydana gelen biniş ve iniş hareketlerinden günün her servis zamanı için başlangıç-varış matrisleri ve maksimum talep düzeylerini hesaplayan bir algoritma uygulanmıştır. Her hat için 15 günlük veriden günün her servis zamanı için maksimum talep miktarlarını tahmin edecek çok katmanlı algılayıcı tipinde bir yapay sinir ağı geliştirilmiştir. Gelecek için yapılan maksimum talep düzeyleri ile diğer hat verilerini kullanarak optimum sefer sıklığını hesaplayan bir algoritma yazılıma eklenmiştir. Bu algoritma yardımı ile her servis zamanı için optimum sefer sıklığının ne olması gerektiğini belirlemek amaçlanmıştır.

4.6. ARAŞTIRMANIN LİTERATÜRE KATKISI

Literatürde ulaşım planlamasında akıllı kart verilerinin kullanımına yönelik çalışmaların genellikle hat performans ölçümü, tüketici davranış analizi ve biniş duraklarından iniş duraklarının tahmin edilmesi konularına odaklandığı görülmüştür. Başlangıç-varış matrislerinin tahminine yönelik çalışmalar da mevcuttur. Akıllı kart verileri ile talep öngörüsüne ve optimum sefer sıklığının ilişkin yabancı literatürde önemli düzeyde çalışma mevcuttur. Yerli literatürde bahsi geçen bu konularda çok az yayın bulunmaktadır. Hem yerli hem de yabancı literatürde çoğunlukla işletme maliyetleri, verimliliği, durakta bekleme süresini ve araçta seyahat süresini optimize eden modeller bulunmaktadır. Ancak, kalabalıklık gibi kalite algısını etkileyen önemli bir faktörü içeren yeterince model bulunmamaktadır. Bu çalışma özellikle ülkemiz literatüründeki modellere yolcuların durakta bekleme süresi, m^2 'ye düşen yolcu sayısı gibi kalite unsurlarını ekleyen bir model önerilmiştir. Hatta modele m^2 'ye düşen yolcu sayısının 2,86'dan küçük olması şeklinde bir sistem kısıtı eklenerek kalabalıklık için sınırlayıcı bir standart getirilmiştir.

Bu çalışmada ayrıca matematiksel modeli çözümlmek üzere basit bir algoritma önerilmiştir. Bu algoritma alt ve üst sınırları belirli, bir veya iki karar değişkeni içeren doğrusal programlama veya hedef programlama modellerini çok hızlı bir şekilde çözme potansiyeline sahiptir. Bu algoritma kısıtların izin verdiği en iyi çözümü mutlaka elde eden bir algoritmadır. İki den fazla değişken olması durumunda hesaplama zamanı artsa da mevcut kısıtlar altında en iyi çözüme ulaşılabilir. Ancak çok değişkenli büyük modeller için yöntem denenmemiştir.

4.7. VERİLERİN ELDE EDİLMESİ

ESHOT Genel Müdürlüğü Ulaşım Planlama Daire Başkanlığı İstatistik Şube Müdürlüğü yetkilileriyle iki aylık bir süreç içinde görüşmeler yapılmış ve gerekli izinler alınarak akıllı kart verileri elde edilmiştir. ESHOT akıllı kart verileri 01/05/2015 ile 15/05/2015 tarihleri arasındaki 15 günlük veriyi ve 02/10/2017-31/10/2017 tarihleri arasındaki 30 günlük veriyi kapsamaktadır. 2015 yılı verileri prototip uygulamanın geliştirilmesinde kullanılmıştır. Bu verilerin yanı sıra İzmir çapında otobüslerin çalıştıkları hatlar, hatlara ait duraklar, otobüsler, çalışma saatlerine ilişkin verilerde ESHOT yetkililerinden alınmıştır. Verilere ilişkin istatistikler tablo 8’de gösterilmiştir.

Tablo 8’de 464.057 adet akıllı kart sahibi bulunduğı ve bu kart sahiplerinin ortalama günde 953.009 biniş yaptıkları görölmektedir. Hat sayısının 310, durak sayısının 5.178 ve Otobüs sayısının 1.516 olduğı görölebilir. Veri tabanında ortalama olarak günde 101,623 kb; ayda 3 gb ve yılda 36,2 gb veri birikmektedir. ESHOT Genel müdürlüğü sadece son 6 ayın verisini sakladığını bildirmiştir. 15 günlük binişlerin günün saat dilimlerine dağılımı Tablo 9’da gösterilmiştir.

Tablo 8 : ESHOT Akıllı Kart Verilerine İlişkin Temel İstatistikler

Gün	Akıllı Kart Sahibi Kullanıcı Sayısı	Hat Sayısı	Durak Sayısı	Otobüs Sayısı	Biniş sayısı	Büyüklik (KB)
1	322.340	278	4.660	1.235	716.425	94,132
2	346.584	278	4.668	1.258	775.526	81,884
3	271.243	252	4.585	1.044	601.177	63,500
4	450.469	286	4.918	1.507	1.064.823	112,340
5	461.003	285	4.929	1.493	1.092.001	115,188
6	464.057	286	4.930	1.490	1.099.803	116,020
7	450.076	286	4.948	1.502	1.061.598	111,996
8	453.268	286	4.944	1.508	1.064.885	112,340
9	384.268	310	5.178	1.323	871.745	92,028
10	279.176	225	4.109	934	627.859	63,344
11	448.325	284	4.876	1.494	1.061.178	112,024
12	449.380	284	4.926	1.506	1.066.410	112,580
13	454.663	286	4.900	1.507	1.079.809	113,998
14	448.170	288	4.934	1.499	1.061.583	111,988
15	445.514	287	4.963	1.516	1.050.306	110,980
En Büyük	464.057	310	5.178	1.516	1.099.803	116,020
En Küçük	271.243	225	4.109	934	601.177	63,344
Ortalama	408.569	280	4.831	1.388	953.009	101,623
Sapma	69.219	19	247	189	181.886	18,442

Tablo 9: Binişlerin Günün Saat Dilimlerine Dağılımı

Saat	Ortalama	Maksimum	Minimum	Standart Sapma
05:00-05:59	421	539	146	128,406
06:00-06:59	31.445	39.700	9.608	11.323,519
07:00-07:59	84.665	110.564	19.434	35.844,940
08:00-08:59	77.281	98.557	23.853	28.740,491
09:00-09:59	44.367	53.364	24.101	10.632,331
10:00-10:59	42.704	50.538	27.742	7.677,119
11:00-11:59	46.810	53.624	33.306	6.881,078
12:00-12:59	56.376	62.762	39.717	6.991,827
13:00-13:59	57.885	66.915	44.696	5.806,723
14:00-14:59	60.446	66.110	47.561	5.961,272
15:00-15:59	65.463	74.854	44.543	11.551,077
16:00-16:59	69.179	80.591	44.133	14.510,578
17:00-17:59	70.458	82.016	45.403	13.132,404
18:00-18:59	71.233	82.573	46.458	13.009,666
19:00-19:59	61.482	69.533	39.668	10.407,762
20:00-20:59	41.744	46.371	31.904	4.218,412
21:00-21:59	28.468	32.530	24.435	2.133,175
22:00-22:59	23.369	26.606	20.520	1.744,246
23:00-23:59	16.062	20.200	12.854	2.183,208
00:00-00:59	3.103	9.554	0	2.515,560
01:00-01:59	31	229	0	57,069
Toplam	952.994	1.099.803	601.144	181.896,648

Tablo 9’da en yüksek biniş sayısının 07:00-07:59 saat diliminde gerçekleştiği, ikinci olarak ta 08:00-08:59 zaman diliminde olduğu görülmektedir. Binişlerin hafta

içi ve hafta sonundaki saatlik dilimlere dağılımları Tablo 10’da gösterilmiştir. Tablo 10’da hafta sonlarında talebin öğlen saatlerinde (13:00-14:59) yoğunlaştığı, hafta içlerinde ise sabah erken zaman dilimlerinde yoğunlaştığı (07:00-08:59) görülmektedir.

Tablo 10: Binişlerin Hafta İçinde ve Hafta Sonunda Günün Saat Dilimlerine Dağılımı

Hafta Sonu					Hafta İçi			
Saat	Ortalama	Maksimum	Minimum	Standart Sapma	Ortalama	Maksimum	Minimum	Standart Sapma
05:00-05:59	284	516	146	163,198	471	539	275	69,198
06:00-06:59	16.149	23.837	9.608	7.318,078	37.008	39.700	19.087	5.985,105
07:00-07:59	35.901	54.897	19.434	18.181,307	102.397	110.564	42.074	20.064,677
08:00-08:59	39.111	57.238	23.853	16.645,886	91.161	98.557	41.054	16.690,749
09:00-09:59	30.460	39.392	24.101	7.551,078	49.424	53.364	31.929	5.972,078
10:00-10:59	32.433	39.063	27.742	5.346,165	46.439	50.538	35.046	4.049,034
11:00-11:59	38.340	45.358	33.306	5.720,691	49.890	53.624	38.002	4.163,515
12:00-12:59	50.763	58.152	44.802	6.029,301	58.417	62.762	39.717	6.351,988
13:00-13:59	56.153	66.915	49.286	8.035,889	58.514	62.927	44.696	5.118,250
14:00-14:59	54.054	63.333	47.561	7.507,579	62.770	66.110	54.160	3.249,538
15:00-15:59	50.879	59.528	44.543	6.986,938	70.767	74.854	48.589	7.492,297
16:00-16:59	50.534	60.265	44.133	7.526,685	75.959	80.591	47.867	9.389,678
17:00-17:59	53.399	63.590	45.403	9.178,118	76.662	82.016	54.503	7.578,463
18:00-18:59	53.932	62.654	46.458	8.282,933	77.524	82.573	56.139	7.287,452
19:00-19:59	46.973	55.609	39.668	7.154,700	66.758	69.533	53.321	4.632,919
20:00-20:59	36.587	41.872	31.904	4.104,963	43.619	46.371	39.731	2.312,910
21:00-21:59	28.313	32.530	24.435	3.511,136	28.525	30.730	25.919	1.630,644
22:00-22:59	23.186	26.606	20.520	2.664,684	23.436	25.582	21.108	1.452,869
23:00-23:59	16.783	20.200	13.928	2.633,657	15.800	19.593	12.854	2.075,805
00:00-00:59	4.717	9.554	0	3.955,661	2.516	4.177	0	1.656,529
01:00-01:59	72	229	0	106,161	16	48	0	15,921
Toplam	719.021	871.555	601.144	127.364,220	1.038.075	1.099.803	716.425	107.677,860

4.8. PROTOTİP UYGULAMA

Çalışmanın bu bölümünde öncelikle verilerden kart kullanıcıların biniş yaptıkları durakları ve iniş durakları belirlenerek her hat için başlangıç-varış (BV) matrisleri hesaplanmıştır. Daha sonra BV matrislerini kullanarak her hat için her saat dilimindeki maksimum talep düzeyi hesaplanmıştır. Geliştirilen algoritmalar ESHOT Genel Müdürlüğü’nden alınan 15 günlük veri ile “Otogar-Konak” hattı için uygulanmış ve test edilmiştir.

4.8.1. Akıllı Kart Veri Yapısı

Veri tabanındaki verilerden kartID, Hat kodu, tarih, saat, biniş durağı, otobüsID, Durak sıra no, Yön gibi verilerden faydalanarak öncelikle her hattaki

duraklardaki biniş sayıları hesaplanacaktır. Akıllı kart biniş verilerinin yapısına örnek Tablo 11’de gösterilmiştir.

Tablo 11: ESHOT Akıllı Kart Verilerinden Bir Kesit

TARİH	KART_ID	HAT_NO	YON	BİNİS_ZAMANI	BİNİS_TİPİ	DURAK_ID	SIRANO	BUS_ID
01.05.2015	10600002158529	27181	Gidiş	01.05.2015 5:32	Normal	11554	5	27288
01.05.2015	61001001278769	28041	Gidiş	01.05.2015 5:35	Normal	10722	2	26528
01.05.2015	61401001016594	28041	Gidiş	01.05.2015 5:35	Normal	10722	2	26528
01.05.2015	61001001077911	28041	Gidiş	01.05.2015 5:36	Normal	10720	3	26528
01.05.2015	61301000113611	28041	Gidiş	01.05.2015 5:36	Normal	10720	3	26528
01.05.2015	10300000350112	27181	Gidiş	01.05.2015 5:37	Normal	14325	10	27288
01.05.2015	61400004739587	27181	Gidiş	01.05.2015 5:37	Normal	14325	10	27288
01.05.2015	61301000521581	28041	Gidiş	01.05.2015 5:38	Normal	10718	4	26528

Tablo 11’de görüldüğü gibi sadece akıllı kart kullanıcısının binişine ilişkin bilgi mevcuttur.

4.8.2. Trépanier, Chapleau ve Tranchant (2007) ve Diker (2015) Yaklaşımları Kullanılarak İniş Duraklarının Tespiti

Kullanıcıların biniş bilgilerinden faydalanarak Trépanier, Chapleau ve Tranchant’nin 2007’deki çalışmalarındaki yolculuk zincirleme yaklaşımı ile, Diker’in 2015’deki çalışmasında gösterdiği rastgele atama tahmin yöntemine dayanan bir algoritma kullanılarak iniş durakları tahmin edilmiştir.

4.8.2.1. Verilerin Yolculuk Zincirleme İçin Hazırlanması

4.8.2.1.1. Veri Birleştirme

Yolculuk zincirleme ve rastgele atama tahmin yönteminin kodlanmasına başlamadan önce binişlere ilişkin hareket tablosunda bulunan HAT_NO, DURAK_ID ve BUS_ID verileriyle Servis hareketleri tablosunda bulunan HAT_ADI, DURAK_AD ve PLAKA verilerinin eşleştirilmesi yoluyla iki tablodaki veriler birleştirilmiştir. Veri Birleştirme için EK 1’deki sql kodları yazılmış ve işletilmiştir. Bu işlem 8 dakika 24 saniyede tamamlanmıştır.

4.8.2.1.2. Otogar – Konak Hattında İşlem Gören Akıllı Kart Verilerinin Özetlenmesi

Prototip uygulama “23021” nolu “Otogar – Konak” hattında uygulanacağından sadece bu hattı ilgilendiren verilerin özetlenmesi gerekmiştir. Bunun için 23021 nolu hatta işlem gören kartların belirlenmesi ve sadece bu kartlara ilişkin tüm hareketlerin BINISLER tablosuna aktarılması sağlanmıştır. Bu işlem için yazılan sql kodu Ek 2’de yer almaktadır.

Böylece algoritmaların 14.295.128 kayıt üzerinde değil 1.142.525 kayıt üzerinde çalışması sağlanmıştır. Bu işlemler 8 saat 3 dakika 17 sn’de tamamlanmıştır.

4.8.2.2. Yolculuk Zincirleme Yaklaşımı

Trépanier ve arkadaşlarının önerdiği yolculuk zincirleme yöntemine ilişkin kodlar Ek 3’de yer almaktadır.

Ek 3’deki kodlar sayesinde önce aktarmalar tespit ediliyor. Eğer aktarma aynı hat üzerindeki bir duraktan yapılmışsa bir önceki hareketin iniş durağı olarak bu durak belirleniyor. Aksi durumda ise önceki hattaki duraklardan aktarma durağına en yakın mesafedeki durak iniş durağı olarak belirleniyor.

Her akıllı kart kullanıcısının sabah ilk seferindeki iniş durağı olarak akşam son seferindeki biniş durağı veya 23021 nolu hatta bu durağa en yakın durak belirleniyor. Aynı şekilde akşam dönüş için iniş durağı ise sabahın ilk hareketindeki biniş durağı veya bu durağa en yakın durak olarak belirleniyor. En yakın durak belirlenirken mesafenin yürüyüş mesafesi (1,5 km veya daha az) olması şartı aranıyor. Bu şart sağlanmazsa iniş durağı belirlenememiş oluyor.

Bu kodun aktarmalara göre işleyen kısmı ile 23021 nolu hattaki 128.510 biniş için 55.250 iniş durağı tahminlenebilmiştir. Bu verilerin % 42,99’unu oluşturmaktadır. Kodun bu kısmı 2 saat 40 dakikada tamamlanmıştır.

Günün ilk ve son binişlerinden ise 23021 nolu hattaki binişlerin 29.632’si için iniş durağı tahmin edilebilmiştir. Bu sayı verilerin yaklaşık % 23,06’sını oluşturmaktadır. Bu iki algoritma yardımıyla 23021 nolu hat için iniş duraklarının yaklaşık % 66,05’i tahmin edilebilmiştir. Binişlerin daha % 33,95’i için iniş durağının tahminlenmesi gerekmektedir. Bu durakların tahmin edilebilmesi için Diker’in

Rastgele Atama Tahmin Yöntemi ve son durağın iniş durağı atamasına ilişkin algoritmaları kullanılacaktır.

Aktarma durağından önceki hattaki iniş durağını bulan algoritmanın tespit ettiği iniş duraklarına bazı örnekler Ek 9'da, Sabah ve akşam binişlerinden o binişlere ilişkin iniş duraklarının tespitine örnekler ise Ek 10'da sunulmuştur.

4.8.2.3. Diker'in Rastgele Atama Tahmin Yöntemi ve Son Durağı Atama Yöntemi

Algoritmanın bu bölümünde Diker'in 2015 yılında tamamladığı doktora tezinde önerdiği algoritma kodlanmıştır. Oluşturulan algoritma Ek 3'te verilen kodlarda görülebilir. Bu algoritmanın çalışması yaklaşık 25 dakika sürmektedir. Bu algoritma kısmı ile iniş duraklarının 42.202'si yani % 32,84'ü yolculukların duraklara dağılımına uygun olarak tahmin edilebilmiştir. Bu yöntem ile belirlenen iniş durakları örnekleri Ek 11'de görülebilir.

Rastgele atama tahmin yöntemi ile tahmin edilemeyen 1.426 (% 1,11) iniş durağının biniş duraklarının bulunduğu yöndeki en son durak olarak belirlenmesini sağlayan bir algoritma yazılmıştır. Bu kod Ek 3'teki kodlarda görülebilir. Algoritmanın çalışması yaklaşık 2 dakika sürmüştür. Bu algoritma ile 1.426 iniş durağı biniş yönündeki son durak olarak belirlenmiştir. İniş durağı olarak son durağın belirlendiği örnekler Ek 12'de görülebilir. Bu algoritma da uygulanınca iniş duraklarının tamamı tahmin edilebilmiştir.

4.8.2.4. Biniş Duraklarından İniş Duraklarını Tahminleyen Algoritmanın Sözde Kodu

Trépanier ve arkadaşlarının önerdiği yolculuk zincirleme ve Diker'in önerdiği rastgele atama tahmin yöntemine göre oluşturulan algoritmanın sözde kodu sözde kod 1'de gösterilmiştir.

Sözde Kod 1: Yolculuk Zincirleme ve Rastgele Atama Tahmin Yöntemi

Başla
Hatta ilişkin durakların listesini oluştur
Hatta işlem gören KART_ID'lerini belirle
Her KART_ID için
Binişleri zaman göre sırala
Aktarma olan durakları belirle
Her aktarma için
Hat duraklarının aktarma durağına uzaklıklarını hesapla
Aktarma durağına en yakın hat durağını bul
Eğer bu durağın önceki biniş durağına uzaklığı 1,5 km'den küçükse önceki binişin iniş durağı olarak belirle
Sabah ve akşam biniş duraklarını belirle
Sabahki binişin yönündeki durakların akşam biniş durağına uzaklıklarını hesapla
Akşam biniş durağına en yakın durağı bul
Eğer bu durakla akşamki biniş durağı arasında mesafe 1,5 km'den küçükse sabahki binişin iniş durağı olarak belirle
Akşamki binişin yönündeki durakların sabahki biniş durağına uzaklıklarını hesapla
Sabah biniş durağına en yakın durağı bul
Eğer bu durağın sabahki biniş durağına uzaklığı 1,5 km'den küçükse akşamki binişin iniş durağı olarak belirle
Geçici başlangıç – varış matrisini oluştur
Belirlenen biniş ve iniş duraklarının dağılımlarını hesapla
Hattaki her biniş kaydı için
Biniş ve iniş duraklarının dağılımlarına uygun olarak aday iniş duraklarının seçilme olasılığını hesapla
Rastgele üretilen bir sayı olasılık değerleriyle karşılaştırılarak iniş durağı belirlenir.
İniş durağı belirlenemeyen duraklar için hattın o yöndeki son durağını iniş durağı olarak belirle
Kalıcı başlangıç – varış matrisini oluştur
Bitir

Sözde koddan anlaşılabilceği gibi önce aktarma yapılan duraklardan önceki binişin iniş durağı tespit edilmektedir. Bu süreç tamamlanınca günün ilk ve son binişlerinden iniş durağı tahmin edilmeye çalışılıyor. Önce ilk biniş durağından son binişin iniş durağı, daha sonra son durağın biniş durağından ilk durağın iniş durağı tahmin ediliyor. Bu iki basamakta elde edilen biniş ve iniş durakları kullanılarak istenilen zaman dilimi için durak seviyesinde BV matrisi hesaplanıyor. Algoritma, BV matrise dayalı olarak biniş ve inişlerin dağılımları ve biniş duraklarına göre sonraki her durakta iniş yapma olasılıkları hesaplanıyor. Bu olasılıklara uygun olarak iniş

durağı her kayıt için tahmin ediliyor. Bu yöntemle de iniş durağı belirlenemeyen kayıtlar için hattın ilgili yöndeki son durağı iniş durağı olarak kabul ediliyor.

4.8.2.5. Kullanıcı Biniş ve İniş Durakları ile Başlangıç-Varış (BV) Matrislerinin Oluşturulması ve Maksimum Talep Düzeyinin Hesaplanması

Duraklardaki biniş ve inişler tespit edildikten sonra her hat için başlangıç-varış (BV) matrisleri hesaplanmıştır. Bu matrisin satır ve sütunları hattın duraklarını gösterir. Satır ve sütunların kesişimindeki hücreler ise iki durak arasında seyahat eden yolcu sayısını göstermektedir. Algoritmanın sözde kodu sözde kod 2’de gösterilmiştir.

Sözde Kod 2: BV Matrisi Oluşturma İçin Kullanılan Algoritmanın Sözde Kodu

```
Başla
İstenen hattın istenilen yönü için biniş veri setini yükle
İstenen hattın istenilen yönü için durak listesini oluştur.
Durak sayısı kadar satır ve sütundan oluşan bir boş BV matrisi oluştur.
Biniş veri setinin ilk kaydına git.
    Veri seti bitene kadar devam et
    Kayıttaki biniş ve iniş durağına karşılık gelen BV matrisi hücresinin
    değerini 1 arttır.
    Veri setindeki sonraki kaydı oku
Bitir
```

BV matrisinden hareketle Şekil 2’de gösterildiği gibi hattın farklı kesimlerinde seyahat eden yolcu sayıları hesaplanacaktır. Yolcu sayısının en fazla olduğu kesim tespit edilip bu kesimdeki yolcu sayısı maksimum talep düzeyi olarak belirlenecektir. Başlangıç-varış matrisini hesaplayan kod Ek 5’te ve hat taleplerinin hesaplanması için kullanılan algoritma Ek 6’da yer almaktadır. Otogar-Konak Hattı için hesaplanan talep düzeyleri Ek 7’de sunulmuştur.


4.9. PROTOTİP UYGULAMA İÇİN VERİ ANALİZİ

Algoritma sadece bir hat için çalışacak şekilde düzenlenerek bir prototip oluşturulması planlanmıştır. Prototip uygulama “Otogar-Konak” hattı esas alınarak geliştirilecektir. Bu hattın seçilmesinin temel nedeni Konak durağının birçok hatla bağlantısı olması ve Otogar’ın İlin diğer il ve ilçelerle bağlantı noktası olmasıdır. Bu nedenle de bu hattın yoğun talep alabileceği düşünülmüştür.

Otogar-Konak hattında 1 Mayıs -15 Mayıs 2015 tarih aralığında 135.456 hareket mevcuttur. Günlük ortalama 9.029 biniş hareketi bulunmaktadır. Bu hatta bu tarih aralığında akıllı kartını kullanan kullanıcı sayısı 56.253'tür.


Prototip uygulamayı hazırlamadan önce verilerin dağılımlarını inceleyip akıllı kart kullanımının hangi saat dilimlerinde daha yoğun, hangi saat dilimlerinde ise daha seyrek olduğunu görmek faydalı olacaktır. Yapılan frekans analizleri neticesinde hafta içindeki akıllı kart kullanımları Şekil 18'de, hafta sonunda akıllı kart kullanımı Şekil 19'da ve 15 günün ortalama akıllı kart kullanımı Şekil 20'de gösterilmiştir.

Şekil 18: Hafta İçi Akıllı Kart Kullanımlarının Dağılımı




Şekil 18'de görüldüğü gibi sabah saatlerinde ve akşam üstüne doğru yoğun bir akıllı kart kullanımı vardır. Sabah saatlerinde insanların işe gittikleri ve akşam üstü evlerine döndükleri düşünülürse dağılımın bu şekilde çıkması olağandır. Özellikle sabah 07:00-07:59 zaman aralığında yoğun bir talep mevcuttur. Grafiğin 2. Pik noktası saat 15:00-15:59 zaman aralığında gerçekleşmektedir.

Şekil 19: Hafta Sonu Akıllı Kart Kullanımlarının Dağılımı



Şekil 19'dan sabah saatlerinde akıllı kart kullanımının düşük olduğu, öğle saatlerinde özellikle 13:00-14:59 zaman aralığında kullanımın en üst düzeyde olduğu görülmektedir. Akşam saatlerinde de seyrek bir kullanım olduğu anlaşılmaktadır.

Şekil 20: 15 Günlük Akıllı Kart Verilerinin Genel Dağılımı




Şekil 20'de sabah saatlerinde ve öğleden sonra yoğun bir akıllı kart kullanımı olduğu anlaşılmaktadır. Sabah 07:00'da en yüksek kart kullanımının olduğu, saat 15:00'da ikinci bir tepe noktası meydana geldiği görülmektedir. Genel ortalamada sabah 06:00-08:00 zaman aralığında ve öğlen 13:00-17:00 zaman aralığında yoğun şekilde kart kullanımı olduğu görülmüştür. Akşam saatlerinde kullanımın ciddi ölçüde azaldığı söylenebilir.

Akıllı kart verileri ve algoritmalar ile elde edilen bilgilerden gidiş yönünde 69.358, dönüş yönünde ise 66.098 hareket olduğu görülmüştür. Biniş ve iniş hareketlerinin duraklara dağılımı hesaplanmıştır. Gidiş yönündeki hareketler Şekil 21’deki, dönüş yönündeki hareketler ise Şekil 22’deki grafikte gösterilmiştir.

Şekil 21’de üç bölgede binişlerin yoğun olduğu görülmektedir. Otogar durağında, Altındağ Belediyesi – Havuzlu Kahve bölgesinde ve Doğum Hastanesi – Ziya Gökalp İlköğretim Okulu – Eşrefpaşa Hastanesi bölgesinde binişler yoğunlaşmaktadır. Beklendiği gibi, hattın son duraklarında binişlerin azaldığı ve son durakta sıfır olduğu görülmektedir. İnişlerin ilk durakta sıfır Ağır Bakım durağına kadarki duraklarda çok az olduğu, Ağır Bakım durağından itibaren dalgalı da olsa bir artış eğilimi gösterdiği görülmektedir. İnişler özellikle Çardak durağından sonra artmakta ve iskele durağında en fazla iniş gerçekleşmektedir.


Şekil 21: Biniş ve İniş Hareketlerinin Otogar - Konak Hattının Gidiş Yönündeki Duraklarına Dağılımı



Şekil 22’de en fazla binişin Konak durağında gerçekleştiği, Borsa – Çardak – Basmane Gar ve Kemer 1 duraklarında yoğun binişler olduğu görülmektedir. Kemer 1 durağından sonra kademeli olarak binişler azalmaktadır. İlk duraklardan Karataş durağında önemli düzeyde iniş görülmektedir. İnişler özellikle Eşrefpaşa Hastanesi ile

MTK Birinci Giriş durağına kadar azalan bir eğilim gösterirken bu duraktan itibaren inişlerde dalgalı da olsa bir artış eğilimi göstermektedir. İnişlerin en fazla olduğu duraklar: Havuzlu Kahve, Altındağ Belediyesi ve Otogar Kavşağıdır.

Şekil 22: Biniş ve İniş Hareketlerinin Otogar - Konak Hattının Dönüş Yönündeki Duraklarına Dağılımı



4.9.1. Verilerin Veri Madenciliği Yöntemleri ile İncelenmesi (Kart Kullanım Kalıplarının Belirlenmesi)

4.9.1.1. Verilerin Kümeleme Analizine Hazırlanması

Verilerin kümeleme analizi için uygun forma sokulması gerekmektedir. Kümeleme analizinde kullanıcıların hareketleri durak, gün, saat verilerine göre değerlendirilecektir. Bir kart sahibi 15 günün farklı zaman dilimlerinde çeşitli duraklardan biniş yapmaktadır. Bu binişlerin 3 adet olduğu düşünülürse veritabanında 3 adet kayıt oluşturduğu görülmektedir. Bu 3 kaydın tek bir kayıt altında toplanması gerekir. Örneğin Tablo 12'deki veriler Tablo 13'teki şekilde tek bir kayda dönüştürülmelidir.

Tablo 12: Bir Yolcunun Yolculuk Verilerine Örnek

Kart_ID	X	Y	Gün	Saat
1251298	38,37632	27,19217	1	9:00
1251298	38,38395	27,16816	1	18:00
1251298	38,3723	27,19104	2	09:30
1521142	38,38245	27,17591	1	09:00
1521142	38,39602	27,13404	1	17:15

Tablo 13: Yolcunun Verilerinin Kümeleme Analizine Uygun Formu

Kart_ID	X1	Y1	Gün1	Saat1	Dakika1	X2	Y2	Gün2	Saat2	Dakika2	X3	Y3	Gün3	Saat3	Dakika3
1251298	38,37632	27,19217	1	9	0	38,38395	27,16816	1	18	0	38,3723	27,19104	2	9	30
1521142	38,38245	27,17591	1	9	0	38,39602	27,13404	1	17	15	Null	Null	Null	Null	Null

Tablo 13'te ikinci Kart_ID için x3, y3, gün3, saat3 ve dakika3 sütunlarında yazan “Null” verisi boş anlamına gelir. Veri madenciliği açısından eksik veri olarak değerlendirilebilir. Verilerin bu forma dönüştürülmesi yaklaşık 2 gün sürmüştür.

4.9.1.2. Eksik Verilerin Değiştirilmesi (Imputation)

Veri madenciliği sürecinde verinin yapısına ve analizi yapanın tercihlerine göre eksik verilerin anlamlı veriler haline dönüştürülmesi gerekir. Eksik veriler o veri kümesindeki minimum, maksimum veya ortalama değerlerle değiştirilebilir. Bunların dışında eksik verilerin sıfırla veya kullanıcının tanımladığı herhangi bir veri ile değiştirilmesi mümkündür. Bunun dışında tüm verilerdeki değişimlerden öğrendiği değişkenler arası ilişkilere göre eksik verinin tahmin edildiği imputasyon yöntemleri kullanılabilir. Bir diğer yöntem ise kullanıcı tarafından belirlenen bir değer aralığından rastgele bir sayının atanması şeklinde olabilir. Bu çalışmada hareket olmayan günler için “boş – null” olan verilerin sıfırla değiştirilmesi uygun görülmüştür.

4.9.1.3. Veri Ön İşleme Süreci

Normalizasyon

Veriler maksimum-minimum yöntemine göre 0-1 aralığında normalize edilmiştir. Böylece büyük değerlerden oluşan durak numaralarının baskın gelerek kümeleme sonuçlarını olumsuz etkilemesi önlenmiştir.

Normalizasyon $Normalize(x_i) = \frac{x_i - Minimum}{Maksimum - Minimum}$ formülüne göre yapılırken, denormalizasyon $Denormalize(y_i) = Normalize(x_i) \times (Maksimum - Minimum) + Minimum$ formülüne göre yapılır.

Temel Bileşenler Analizi


Yapılan incelemede ve literatürdeki bazı araştırmalarda (Tatlídil, 1996; Şengöz ve Özdemir, 2016; Öztürk ve Yıldız, 2012) temel bileşenler analizi gibi değişken azaltma yöntemlerinin kullanılması ile kümeleme algoritmalarının verileri daha iyi ayırabildiği gözlenmiştir. Boyut indirgeme aynı zamanda kümeleme için gerekli zamanı da önemli ölçüde azaltmaktadır.

Bu nedenle normalize edilen verilere temel bileşenler analizi uygulanmıştır. Temel bileşenler analizi sonuçları Tablo 14’te, saçılma grafiği (Scree plot) ise Şekil 23’de gösterilmiştir.

Tablo 14: Temel Bileşenler Analizi Sonuçları

Bileşen	Standart Sapma	Varyans Oranı	Kümülatif Varyans
PC1	0,482	0,841	0,841
PC2	0,180	0,117	0,959
PC3	0,098	0,035	0,994
PC4	0,042	0,006	1,000

Şekil 23: Temel Bileşenler Analizi Saçılma Grafiği (Scree Plot)



4.9.1.4. Kümeleme Analizinin Gerçekleştirilmesi

Kart kullanıcıları biniş zamanı ve biniş duraklarına göre K-ortalamlar ve X-Ortalamlar kümeleme algoritmalarıyla kümelendi. Basit ve hızlı bir kümeleme algoritması olan k-ortalamlar yöntemi yaygın bir kullanım alanına sahiptir. Bu yöntemde küme sayısının başta belirtilmesi gerekir ve algoritma verileri belirtilen sayıda kümeye ayırır. Doğru küme sayısının belirlenmesi için Tablo 15’te gösterildiği gibi farklı küme sayıları için algoritma çalıştırılır ve en iyi sonucu veren küme sayısı seçilir. K-ortalamlar yönteminde küme sayısının baştan verilmesi gerekliliği ve yöntemin yerel minimumlara takılabilmesi önemli dezavantajlarıdır. Bu dezavantajları


gidermek için Dan Pelleg ve Andrew Moore x-ortalamalar yöntemini önermişlerdir. X-ortalamar algoritmasında veri seti çok çözünürlüklü kd-ağacına yerleştirilerek ve düğümlerinde yeterli istatistiklerin tutulmasıyla daha hızlı bir algoritma sunmuşlardır. Algoritma Bayesçi Bilgi Kriteri (Bayesian Information Criterion – BIC) ölçütü ile mevcut kümelerin bölünmesine karar vermektedir. Bu algoritma farklı küme sayılarına göre k-ortalamalar yöntemini uygulayıp en uygun küme sayısını tespit etmekten daha hızlı sonuçlanmaktadır (Pelleg ve Moore, 2000). K-ortalamalar yöntemine ve farklı küme sayılarına göre kümeleme sonuçları Tablo 15’te gösterilmiştir.

Tablo 15: Farklı Küme Sayılarına Göre K-Ortalamalar Yönteminin Sonuçları

Uzaklık	K	Davies Bouldin	Küme1	Küme2	Küme3	Küme4	Küme 5
Öklid	2	0,722	56.278	79.192			
	3	0,678	56.956	49.589	26.285		
	4	0,640	20.427	30.306	33.831	50.906	
	5	0,671	28.053	13.138	46.935	28.186	19.158
Chebychev	2	0,725	81.300	54.170			
	3	0,600	44.396	66.144	24.930		
	4	0,640	20.198	30.373	34.158	50.741	
	5	0,679	30.751	13.226	46.250	26.630	18.613
Cosine	2	0,710	73.149	62.321			
	3	0,620	38.984	34.086	62.400		
	4	0,629	23.989	28.182	55.374	27.925	
	5	0,686	18.813	23.720	50.068	22.931	19.938
Dynamic Time Warping	2	0,722	56.278	79.192			
	3	0,594	59.596	49.589	26.285		
	4	0,640	20.427	30.306	33.831	50.906	
	5	0,671	28.053	13.138	46.935	28.186	19.158
Kernel Öklid	2	0,710	73.285	62.185			
	3	0,594	49.544	59.580	26.346		
	4	0,640	33.828	20.431	50.900	30.311	
	5	0,671	28.053	13.138	46.935	28.186	19.158
Uzaklık	K	Davies Bouldin	Küme1	Küme2	Küme3	Küme4	Küme 5
Manhattan	2	1,527	77.678	57.792			
	3	0,594	57.538	26.338	51.594		
	4	0,643	34.130	20.377	51.049	29.914	
	5	0,657	44.198	31.585	21.273	13.719	24.695
Karma Öklid	2	0,722	77.678	57.792			
	3	0,594	59.596	49.587	26.285		
	4	0,640	20.427	30.306	33.831	50.906	
	5	0,671	28.053	13.138	46.935	28.186	19.158
Mahalanobis	2	0,676	27.733	107.737			
	3	0,592	58.645	23.051	53.774		
	4	0,684	13.802	19.878	52.742	49.048	
	5	0,678	42.773	35.246	18.251	13.211	25.989
Kareli Öklid	2	0,722	56.278	79.192			
	3	0,594	59.596	49.589	26.285		
	4	0,640	20.427	30.306	33.831	50.906	
	5	0,672	47.133	28.053	19.094	12.969	28.221

Davies-Bouldin indeksi küme içindeki noktaların küme merkezine uzaklıklarını minimum ve kümeler arasındaki uzaklıkları maksimum yapmayı amaçlar. Bu nedenle Davies-Bouldin değerini minimum yapan küme sayısı uygun küme sayısıdır (Hacıoğlu, 2016: 17-18; Servi, 2009: 77; Selvi ve Çağlar, 2017: 420) . Tablo 15’te en iyi kümeleme sonucunun Mahalanobis uzaklığına göre kart kullanıcıları 3 kümeye ayrıldığında elde edilmiştir. 3 Küme için kümelerin grafiksel gösterimi Şekil 24’te gösterilmiştir.

Şekil 24: Mahalanobis Uzaklığı ve K=3 İçin K-Ortalamlar Yöntemine Göre Kart Kullanıcılarının Kümeleme Dağılımı



Şekil 24’te gösterilen kümeleme analizi neticesinde ilk küme benzer duraklardan benzer zamanlarda binış yapanları (% 43,29), ikinci küme düzensiz binış yapanları (% 17,02) ve üçüncü küme ise benzer duraklardan farklı zamanlarda binış yapanlardır (% 39,69). Benzer duraklardan binış yapanların toplamı kart sahiplerinin % 82,98’inin oluşturmaktadır. Bu durum kart kullanıcılarının çok büyük bir kısmının düzenli seyahat ettiğini ve Trépanier , Chapleau ve Tranchart (2007)’nin temel varsayımlarının geçerli olduğunu göstermektedir.


X-Ortalamlar yöntemine göre kümeleme analizi sonuçları Tablo 16’da gösterilmiştir.

Tablo 16: X-Ortalamlar Yöntemine Göre Kart Kullanıcılarının Kümeleme Analizi Sonuçları

Uzaklık	K	Davies Bouldin	Küme1	Küme2	Küme3	Küme4
Öklid	4	0,626	31.943	48.737	32.974	21.816
Chebychev	4	0,631	48.693	33.663	32.068	21.046
Cosine	4	0,613	52.370	22.563	30.124	30.413
Dynamic Time Warping	4	0,626	48.737	31.943	21.816	32.974
Kernel Öklid	4	0,626	48.737	31.943	21.816	32.974
Manhattan	4	0,623	48.368	30.761	34.351	21.990
Karma Öklid	4	0,626	48.737	31.943	21.816	32.974
Mahalanobis	2	0,788	27.733	107.737		
Kareli Öklid	4	0,626	31.943	48.737	32.974	21.816

Tablo 16’da en iyi sonucun 4 küme için cosine uzaklığı ile elde edildiği görülmektedir. Elde edilen kümelerin grafiksel gösterimi Şekil 25’te gösterilmiştir.

Şekil 25: Cosine Uzaklığı ve K=4 İçin X-Ortalamalar Yöntemine Göre Kart Kullanıcılarının Kümeleme Dağılımı



Şekil 25’de gösterilen kümelemede ilk küme benzer duraklardan benzer zamanlarda biniş yapanlar (% 38,66), ikinci küme düzensiz biniş yapanlar (% 16,66), üçüncü kümede benzer duraklardan farklı zamanlarda biniş yapanlar (% 22,24) ve son olarak dördüncü kümede farklı duraklardan benzer zamanlarda biniş yapanlar (% 22,45) bulunmaktadır. Benzer durakları kullanan kart kullanıcıları toplam talebin % 60,90’lık kısmını oluşturmaktadır. Bu sonuçta kart kullanıcılarının yarısından fazlasının benzer durakları kullanan kişiler olduğunu göstermektedir.

K-ortalamalar (% 82,98) ve x-ortalamalar (% 60,9) yönteminde akıllı kart kullanıcılarının büyük kısmının benzer duraklardan biniş yaptıkları tespit edilmiştir. Bu durum Trépanier ve arkadaşlarının önerdiği yolculuk zincirleme yönteminin temel varsayımlarına uyan kart kullanıcılarının çoğunlukta olduğunu göstermektedir. Bu nedenle yolculuk zincirleme algoritmasının başarı ile uygulanabileceği düşünülmüştür.


4.9.2. Hatlara İlişkin Maksimum Talep Düzeylerini Tahminleyen Yapay Sinir Ağı Yaklaşımı

15 günlük veriden hesaplanan hatlara ilişkin saatlik talep düzeylerinin 10 günlük kısmı yapay sinir ağının eğitimi, 5 günlük kısmı ise test edilmesi için kullanılacaktır. Geliştirilen yazılımda, tahminleme için gecikmeli bir çok katmanlı algılayıcı tipinde bir YSA modeli yazılmıştır.

4.9.2.1. Geliştirilen Çok Katmanlı Algılayıcı Tipindeki İleri Beslemeli Yapay Sinir Ağı Modeli

Geliştirilen YSA'da 1 giriş katmanı, 1 gizli katmanı ve 1 çıkış katmanı bulunmaktadır. Girdi katmanında 2 çıktı katmanında 1 sinir hücresi yer almaktadır. Gizli katmandaki sinir hücresi sayısı deneysel çalışma ile belirlenmiştir. YSA'nın temsili yapısı Şekil 26'da gösterilmiştir. Giriş katmanına hatların ilgili saat için maksimum talep düzeyleri son 2 günün verisi olacak şekilde uygulanacaktır. Veriler 2 günlük gecikme ile uygulanmıştır. YSA geri yayılım algoritması ile eğitilmiştir. K kez çapraz doğrulama yöntemi ile YSA'nın öğrenmesi kontrol edilmiş ve belirli aralıklarla test verisi kullanılarak YSA'nın genelleme yeteneği ölçülmüştür. YSA'nın genelleme yeteneği bozulmaya başladığında (yani ezberleme başladığında) eğitim durdurulmuştur.

Şekil 26: Geliştirilen yapay sinir ağının yapısı



4.9.2.2. Geliştirilen YSA'nın Performansının Belirlenmesi

Yapay sinir ağının yeterince eğitildiğini anlamak için performans ölçütlerine ihtiyaç bulunmaktadır. Yazında genellikle Ortalama Mutlak Sapma (MAE), Hata Kareleri Ortalaması (MSE), Hata Kareleri Ortalamasının Karekökü (RMSE) ve Ortalama Mutlak Yüzde Hata (MAPE) değerleri kullanıldığı görülmektedir: (Kaynar ve Taştan, 2000; Çuhadar ve Kayacan, 2005; Asilkan ve Irmak, 2009; Kheirkhah vd., 2013; Adamowski vd., 2012). Yapay sinir ağının eğitiminde ve testinde bu değerler kullanılarak performans ölçülecektir.

4.9.2.3. Geliştirilen Yapay Sinir Ağının Parametre Optimizasyonu

Çok katmanlı algılayıcının performansını etkileyebilen bazı parametreler bulunmaktadır. Bunların ilki gizli katmandaki sinir hücresi sayısıdır. Diğer parametreler: öğrenme katsayısı, momentum, gizli katman ve çıktı katmanındaki aktivasyon fonksiyonları ve son olarak başlangıç ağırlıklarının değer aralığıdır. Tüm bu parametreler deneysel çalışma ile belirlenecektir.

4.9.2.4. Aktivasyon Fonksiyonlarının Belirlenmesi

Yazında sıklıkla karşılaşılan aktivasyon fonksiyonları hem gizli katman hem de çıktı katmanı sinir hücrelerinde denenmiştir. Verilere uygun aktivasyon fonksiyonunu bulabilmek için gizli katmanda bir fonksiyon sabit olarak tutulurken çıktı katmanındaki sinir hücresinin aktivasyon fonksiyonu değiştirilmiş ve test edilerek hata kareleri ortalamasının karekökü (RMSE) değerleri karşılaştırılmıştır. Test edilen aktivasyon fonksiyonları sırası ile: Tanjant Sigmoid, Sigmoid, Linear, SoftSign, Üstel Doğrusal Birim – ÜDB, SoftPlus, Sinusoidal, Gaussian, Elliot, Elliot Simetrik Birim – ESB ve Hiperbolik Tanjanttır. Yapay sinir ağının performansı sinir hücreleri arasındaki bağlantıların ağırlık katsayılarına duyarlıdır. Bu nedenle her deneme 50 kez tekrarlanmış ve elde edilen RMSE değerlerinin ortalamaları hesaplanarak Tablo 17 oluşturulmuştur.

Tablo 17’den gizli katman sinir hücrelerinde Sinusoidal aktivasyon fonksiyonunun, çıktı katmanında ise Üstel Doğrusal Birimin kullanılması gerektiği anlaşılmıştır. Tablo 17 hem gizli katmanda hem de çıktı katmanında sinusoidal aktivasyon fonksiyonunun kullanılabileceğini göstermektedir.


Tablo 17: Aktivasyon Fonksiyonunu Belirlemek için Yapılan Deneylerin Sonuçları
(Test RMSE Değerleri Kullanılmıştır)

	Çıktı Katmanı											
		Tanjant Sigmoid	Sigmoid	Linear	SoftSign	ÜDB	SoftPlus	Sinusoidal	Gaussian	Elliot	ESB	Hiperbolik Tanjant
Gizli Katman	Tanjant Sigmoid	9,090	10,757	15,111	13,295	20,079	13,998	12,173	21,163	9,626	13,448	11,617
	Sigmoid	8,777	10,635	14,586	12,503	10,674	13,779	9,537	64,704	9,898	12,529	9,574
	linear	12,444	14,779	22,821	17,745	29,524	26,065	26,803	37,946	13,567	17,379	22,373
	softsign	10,267	13,296	17,398	12,865	18,017	14,245	15,352	16,953	9,037	13,197	11,098
	ÜDB	16,073	18,269	20,663	20,137	22,084	19,379	20,640	12,529	13,880	19,896	18,269
	SoftPlus	19,741	21,643	18,909	22,310	19,572	18,692	19,235	65,167	20,650	22,262	20,488
	Sinusoidal	6,527	7,485	14,500	7,434	3,716	6,082	3,797	6,010	6,856	7,451	6,054
	Gaussian	9,757	14,281	15,523	11,372	11,179	14,306	12,247	26,697	13,465	11,827	11,907
	Elliot	19,925	21,588	16,227	22,088	19,260	20,112	19,484	64,671	20,739	22,032	19,645
	ESB	9,943	13,025	21,775	13,358	19,324	14,469	15,412	17,002	8,930	13,036	11,341
	Hiperbolik Tanjant	7,937	10,216	14,500	11,942	15,251	13,306	8,386	18,388	8,660	11,863	8,917

4.9.2.5. Gizli Katman Sinir Hücresi Sayısının Belirlenmesi

Gizli katman ve çıktı katmanı sinir hücreleri için uygun Aktivasyon fonksiyonunun tespit edilmesinden sonra performansı etkileyebilecek diğer bir unsur olan gizli katman sinir hücresi sayısı deneysel çalışma ile belirlenmiştir. Gizli katman hücre sayısı 1'den 20'ye kadar çıkartılarak her kademede 50 deney yapılmıştır. Deneylerin sonuçları Şekil 27'de gösterilmiştir.

Şekil 27: Gizli Katmandaki Sinir Hücreleri Sayısının Belirlenmesi



Şekil 27’de en iyi sonucu veren gizli katman hücre sayısı 13 olarak tespit edilmiş ve sonraki denemelerde bu şekilde kullanılmıştır. İkinci bir alternatif olarak hücre sayısı 16 olarak belirlenebilir. Deney tasarımı ikinci kademe olarak seçilebilir.

4.9.2.6. Öğrenme Oranı ve Momentumun Belirlenmesi

Yapay sinir ağının performansında en etkili parametrelerden birisi öğrenme oranıdır. Bu oran ağırlıkların değişim miktarını belirler. Küçük öğrenme oranları öğrenmenin yavaşlamasına neden olurken çok büyük değerler yerel minimumlar arasında ağı dalgalanmasına neden olur. Yazında 0,01-0,4 arası değerler tavsiye edilse de yazında daha küçük değerlerin kullanıldığı görülmektedir: Yakut ve arkadaşları 0,01 oranını kullanmıştır (Yakut vd., 2014, s.147), Packianather ve arkadaşları 0,01; 0,03 ve 0,05 değerlerini test etmiş ve 0,01 değerinin daha iyi sonuç verdiğini raporlamıştır (Packianather vd., 2000), Yavuz 2012’deki tezinde 0,009 ile 0,4 arasında değerler denemiş ve 0,05 değerinin en iyi sonucu verdiğini raporlamıştır (Yavuz, 2012: 122).

Momentum katsayısı bir önceki iterasyondaki değişimin belirli bir oranda yeni değişim miktarına eklenmesidir. Bu katsayı ağı daha hızlı öğrenmesi için düşünülmüştür. Momentum değeri çok yüksek seçilirse algoritma büyük sıçramalarla çözüm uzayını araştırır ve tek bir çözüme ulaşmada sorunlar oluşabilir. Çok küçük olması durumunda ise algoritma yerel minimumlara takılabilir. Momentum için yazında genellikle 0,6-0,8 civarında bir değer seçildiği görülmüştür (Öztemel, 2012: 99). Yavuz 2012’deki tezinde 0,2 ile 0,9 arasında değerler denediğini ve en iyi öğrenme performansının 0,7 momentum değeri ile elde edildiğini raporlamıştır. Bu çalışmada öğrenme oranı için 0,01-0,1 arasındaki değerler, momentum içinse 0,1 ile 0,9 arasındaki değerler denenmiş ve test sonuçlarında elde edilen RMSE değerleri Tablo 18’de gösterilmiştir (Yavuz, 2012).

Tablo 18: Öğrenme Katsayısı ve Momentum için Yapılan Test Sonuçlarının RMSE Değerleri

		Momentum									
		0	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
Öğrenme Oranı	0,01	6,462	5,948	5,101	4,274	3,445	3,048	2,651	2,427	2,102	2,000
	0,02	5,817	4,926	3,973	3,500	2,628	2,146	2,087	2,038	1,857	1,787
	0,03	7,055	5,506	3,798	2,958	2,739	2,331	2,016	1,900	1,885	1,830
	0,04	5,597	3,952	2,879	2,408	2,008	1,962	1,820	1,820	1,742	1,736
	0,05	6,248	4,662	2,869	2,066	1,747	1,623	1,549	1,549	1,549	1,549
	0,06	4,729	3,528	2,324	1,953	1,669	1,588	1,548	1,501	1,496	1,496
	0,07	4,368	2,659	2,307	2,150	2,133	1,939	1,794	1,794	1,794	1,794
	0,08	3,367	2,822	2,172	1,976	1,849	1,543	1,490	1,490	1,490	1,490
	0,09	3,886	2,894	2,264	2,050	1,988	1,896	1,772	1,772	1,772	1,772
	0,1	4,345	3,030	2,555	2,277	2,179	1,998	1,821	1,797	1,797	1,797

Tablo 18’de öğrenme oranı 0,08 iken momentumun 0,6 ve üzerindeki değerlerde en iyi hata değerini verdiği görülmektedir. Bu nedenle tasarlanan YSA’nın eğitiminde öğrenme katsayısı 0,08, momentum ise 0,6 olarak seçilmiştir.

4.9.2.7. Başlangıç Ağırlık Katsayılarının Değer Aralığının Belirlenmesi

Çok katmanlı algılayıcıların performansı başlangıçtaki sinir hücresi bağlantılarının ağırlık katsayılarına oldukça duyarlıdır. Çeşitli kaynaklarda farklı sayı aralıklarından rastgele seçilen ağırlık katsayılarının başarılı sonuçlar ürettiği belirtilmektedir: Öztemel 2012’de yayınlanan kitabında başlangıç ağırlık katsayılarının $[-1;0,1]$ aralığında olması gerektiğini raporlamıştır, Paola, 1994’deki çalışmasında Staufer-Steinnocher ise 1997’deki çalışmasında bu ağırlık katsayılarının $[-0,1;0,1]$ aralığında olması gerektiğini raporlamıştır, Gallagher ve Downs 1997 yılında sundukları bildiride başlangıç ağırlıklarının $[-0,25; 0,25]$ aralığında olması durumunda en iyi öğrenmenin sağlandığını belirtmiştir, Kavzoğlu 2001’deki doktora tezinde 8 farklı başlangıç ağırlıkları aralığını test etmiş ve en iyi öğrenmenin $[-0,1-0,1]$, $[-0,15-0,15]$ ve $[-0,25-0,25]$ aralıklarında sağlandığını göstermiştir. Bu çalışmada aralığın alt sınırı ve üst sınırı $[-1; 1]$ aralığından seçilerek 10 alt sınır ve 20 üst sınır için deneyler yapılmıştır. Toplamda $200 \times 50=10.000$ deney yapılarak elde edilen RMSE değerleri Tablo 19’da verilmiştir.

Tablo 19: Başlangıç Ağırlıklarının Değer Aralığı İçin Test Sonuçları

Deney	-1;1	-0,9; 0,9	-0,8;0,8	-0,7;0,7	-0,6;0,6	-0,5; 0,5	-0,4; 0,4	-0,3; 0,3	-0,2; 0,2	-0,1; 0,1
1	6,096	2,103	2,103	2,103	2,103	2,103	2,103	2,103	2,103	2,103
2	2,937	2,937	2,937	2,665	2,665	2,665	2,665	2,665	2,134	2,134
3	5,298	3,022	3,022	3,022	3,022	3,022	3,022	3,022	3,022	3,022
4	7,125	5,369	5,247	5,247	3,532	3,532	3,532	3,532	3,532	3,532
5	2,734	2,734	2,734	2,555	2,555	2,555	2,555	2,555	2,555	2,398
6	1,666	1,666	1,666	1,666	1,666	1,666	1,666	1,666	1,666	1,666
7	3,866	3,866	3,866	3,866	3,069	3,069	3,069	2,547	2,547	2,547
8	5,006	1,394	1,394	1,394	1,394	1,394	1,394	1,394	1,394	1,394
9	3,086	3,086	3,086	2,369	2,369	2,369	2,369	2,369	2,369	2,369
10	9,462	3,331	3,233	3,233	3,233	3,233	3,233	3,233	2,259	2,259
11	3,756	3,756	3,756	3,756	3,756	2,964	2,964	2,964	2,964	1,413
12	6,914	6,914	1,538	1,538	1,538	1,538	1,538	1,538	1,538	1,538
13	5,744	5,744	5,063	5,063	5,063	5,063	3,959	3,959	3,959	3,959
14	8,402	8,402	8,402	2,498	2,498	2,498	2,498	2,498	2,498	2,498
15	7,913	2,880	2,880	2,880	2,880	2,880	2,880	2,880	1,930	1,728
16	3,530	3,530	2,170	2,170	2,170	2,170	2,170	2,170	2,170	2,170
17	3,435	3,435	3,435	3,435	1,483	1,483	1,483	1,483	1,483	1,483
18	5,773	4,503	4,503	4,503	2,574	2,574	2,574	2,574	2,574	2,574
19	11,188	4,231	4,231	4,231	4,231	4,231	4,231	4,231	2,815	2,815
20	3,296	3,296	3,296	3,296	3,296	3,296	3,296	3,296	3,296	3,296
Ortalama	5,361	3,810	3,428	3,075	2,755	2,715	2,660	2,634	2,440	2,345
Sapma	2,521	1,710	1,595	1,114	0,947	0,919	0,795	0,789	0,690	0,721

Tablo 19’da başlangıç ağırlık katsayılarının $[-0,1; 0,1]$ aralığından rastgele seçilmesi durumunda en iyi sonucun alındığı görülebilir. Bu nedenle ağırlık katsayıları bu aralıkta herhangi bir değer alacak şekilde ayarlanmıştır.

4.9.3. Geliştirilen Yapay Sinir Ağı'nın Testi ve Diğer Tahmin Yaklaşımlarıyla Karşılaştırılması

Geliştirilen yapay sinir ağı'nın ne kadar yeterli performansa sahip olduğunu belirlemek için bilinen çeşitli tahmin yöntemlerinin performansları ile kıyaslanmıştır.

4.9.3.1. Eğitimi Tamamlanan Yapay Sinir Ağı ile Yapılan Tahminler ve Hesaplanan İstatistikler

Yapay sinir ağı eğitilip en iyi duruma getirildikten sonra eğitim ve test seti için hesapladığı tahmin değerleri, hata kareleri, mutlak hatalar ve mutlak yüzde hataları Tablo 20’de verilmiştir.

Tablo 20:Yapay Sinir Ağı'nın Sağladığı Tahmin, Hata, Mutlak Hata ve Mutlak Yüzde Hata Değerleri

2 Önceki gün talebi	1 Önceki gün talebi	Gerçek Talep	Tahmin	Hata Kare	Mutlak Hata	Mutlak Yüzde Hata
60	64	23	20	9	3	0,13
64	23	92	98	36	6	0,07
23	92	82	79	9	3	0,04
92	82	85	86	1	1	0,01
82	85	104	101	9	3	0,03
85	104	82	97	225	15	0,18
104	82	59	59	0	0	0,00
82	59	23	23	0	0	0,00
59	23	116	112	16	4	0,03
23	116	104	105	1	1	0,01
116	104	112	106	36	6	0,05
104	112	92	102	100	10	0,11
112	92	91	89	4	2	0,02

Tablo 20’de tahmin değerlerinin gerçekleşen taleplere çok yakın olduğu görülmektedir. Buna bağlı olarak hata kareleri, mutlak hatalar ve mutlak yüzde hatalar çok düşük görünmektedir. Tahmin kalitesini ölçmek ortalama mutlak hata (MAE), ortalama mutlak yüzde hata (MAPE), hata kareleri ortalaması (MSE) ve hata kareleri ortalaması karekökü (RMSE) istatistikleri hesaplanmıştır. MAE’nin formülü denklem 51’de MSE’nin formülü denklem 52’de, RMSE’nin formülü denklem 53’de ve MAPE’nin formülü denklem 54’de gösterilmiştir.

$$MAE = \frac{\sum |y_i - \hat{y}_i|}{n} \quad \text{Denklem 51}$$

$$MSE = \frac{\sum (y_i - \hat{y}_i)^2}{n} \quad \text{Denklem 52}$$

$$RMSE = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n}} \quad \text{Denklem 53}$$


$$MAPE = \frac{\sum |y_i - \hat{y}_i| / y_i}{n} \times 100 \quad \text{Denklem 54}$$

Bu formüllerdeki y_i değeri gerçek talebi, $\hat{y}_i$ değeri ise tahmin değerini ifade eder. n hesaba katılan dönem sayısıdır. Tablo 20’deki veriler ve ilgili denklemler (Denklem 51, 52, 53 ve 54) kullanılarak hesaplanan istatistikler: MAE= 4,175; MSE= 34,192; RMSE= 5,847 ve MAPE= % 5,41’dir. Bütün bu hata ölçülerinin en küçük değere sahip olması istenir.

4.9.3.2. Yapay Sinir Ağı ile Hareketli Ortalamalar Yönteminin Performanslarının Karşılaştırılması

Yapay sinir ağını eğitmek ve test etmek için kullanılan veri setine 2 dönemlik hareketli ortalamalar yöntemi uygulanmıştır. Hareketli ortalamalar ve yapay sinir ağlarının tahmin gücü Şekil 28’de gösterilmiştir.

Şekil 28: Hareketli Ortalamalar Yöntemi ve Yapay Sinir Ağı ile Yapılan Tahminler




Şekil 28’de yapay sinir ağının hareketli ortalama yöntemine göre çok daha yakın tahminler yaptığı görülmektedir. Hareketli ortalamalar için hesaplanan istatistikler: $MAE = 28,231$; $MSE = 1204,810$; $RMSE = 34,710$ ve $MAPE = \% 52,52$ ’dir. Bu değerler de hareketli ortalamalar yöntemi ile yapay sinir ağlarından çok kötü bir tahminleme yapılabileceğini göstermiştir.

4.9.3.3. Yapay Sinir Ağı ile Ağırlıklı Hareketli Ortalamalar Yönteminin Performanslarının Karşılaştırılması

Yapay sinir ağını eğitmek ve test etmek için kullanılan veri setine 2 dönemlik ağırlıklı hareketli ortalamalar yöntemi uygulanmıştır. Bu yöntemde son döneme yakın dönemler daha yüksek katsayılarla ağırlıklandırılırlar. Böylece son zamanlardaki trendin daha yakından takip edilebileceği düşünülerek bu yaklaşım önerilmiştir. Son dönem için 0,8; sondan bir önceki dönem için ise 0,2 ağırlık katsayıları kullanılmıştır. Ağırlıklı hareketli ortalamalar ve yapay sinir ağlarının tahmin gücü Şekil 29’da gösterilmiştir.

Şekil 29: Ağırlıklı Hareketli Ortalamalar Yöntemi ve Yapay Sinir Ağı ile Yapılan Tahminler




Şekil 29’da yapay sinir ağının ağırlıklı hareketli ortalama yöntemine göre çok daha yakın tahminler yaptığı görülmektedir. Ağırlıklı hareketli ortalamalar için hesaplanan istatistikler: MAE= 25,615; MSE= 1249,443; RMSE= 35,347 ve MAPE= % 47,81’dir. Bu değerler de ağırlıklı hareketli ortalamalar yöntemi ile yapay sinir ağlarından çok kötü bir tahminleme yapılabileceğini göstermiştir.

4.9.3.4. Yapay Sinir Ağı ile Üstel Düzeltme Yönteminin Performanslarının Karşılaştırılması

Yapay sinir ağını eğitmek ve test etmek için kullanılan veri setine $\alpha=0,99$ olacak şekilde üstel düzeltme yöntemi uygulanmıştır. Bu yöntemde önceki tahminde yapılan hatalar dikkate alınarak önceki tahmin düzeltilmektedir. Üstel düzeltme yöntemi ve yapay sinir ağlarının tahmin gücü Şekil 30’da gösterilmiştir.

Şekil 30: Üstel Düzeltme Yöntemi ve Yapay Sinir Ağı ile Yapılan Tahminler




Şekil 30’da yapay sinir ağının üstel düzeltme yöntemine göre çok daha yakın tahminler yaptığı görülmektedir. Üstel düzeltme yöntemi için hesaplanan istatistikler: MAE= 24,203; MSE= 1285,403; RMSE= 35,853 ve MAPE= % 34,91’dir. Bu değerler de üstel düzeltme yöntemi ile yapay sinir ağlarından çok kötü bir tahminleme yapılabileceğini göstermiştir.

4.9.3.5. Yapay Sinir Ağı ile Çoklu Doğrusal Regresyon Yönteminin Performanslarının Karşılaştırılması

Yapay sinir ağını eğitmek ve test etmek için kullanılan veri setine çoklu doğrusal regresyon analizi uygulanmıştır. Bu yöntemde geçmiş dönem verilerine en uygun doğru denklemi bulunur ve bu denklem ile geleceğe yönelik tahminler yapılır. Bu yöntem uygulanırken veriler önceki iki dönem regresyon doğrusunun bağımsız değişkenlerini oluşturacak şekilde düzenlenir. Bu düzenleme yapılırken iki dönemlik pencereleme yapılır. İlk bağımsız değişken veri setindeki ilk talep verisinden son bir önceki talep verisine kadar olan talepleri kapsar. İkinci bağımsız değişken ise veri setindeki ikinci talep verisinden sonuncu talep verisine kadar olan talepleri kapsar. Yani ikinci bağımsız değişken aslında ilk değişkenin bir dönem geciktirilmiş halidir. Çoklu doğrusal regresyon analizi ve yapay sinir ağlarının tahmin gücü Şekil 31’de gösterilmiştir.

Şekil 31: Çoklu doğrusal regresyon analizi ve Yapay Sinir Ağı ile Yapılan Tahminler



Şekil 31’de yapay sinir ağının çoklu doğrusal regresyon analizine göre çok daha yakın tahminler yaptığı görülmektedir. Regresyon analizi için hesaplanan

istatistikler: MAE= 21,778; MSE= 810,936; RMSE= 28,477 ve MAPE= % 51,52'dir. Bu değerler de bu veri seti için çoklu doğrusal regresyon yöntemi ile yapay sinir ağlarından daha kötü bir tahminleme yapılabileceğini göstermiştir.

4.9.3.6. Tahminleme Yöntemlerinin Bir Arada Değerlendirilmesi

Yapay sinir ağı, hareketli ortalamalar, ağırlıklı hareketli ortalamalar, üstel düzeltme yöntemleri ve çoklu doğrusal regresyon analizi sonuçları topluca Tablo 21'de gösterilmiştir.

Tablo 21: Tahminleme Yöntemlerine İlişkin İstatistikler

Yöntem	MAE	MSE	RMSE	MAPE
Yapay Sinir Ağı	4,175	34,192	5,847	% 5,41
Hareketli Ortalamalar	28,231	1204,810	34,710	% 52,52
Ağırlıklı Hareketli Ortalamalar	25,615	1249,443	35,347	% 47,81
Üstel Düzeltme	24,203	1285,403	35,853	% 34,91
Çoklu Doğrusal Regresyon Analizi	21,778	810,936	28,477	% 51,52

Tablo 21'de görüldüğü gibi en iyi hata istatistiklerine sahip olan yöntem geliştirilen yapay sinir ağıdır. Yapay sinir ağının eğitiminde sadece 10 dönemlik veri bulunmasına rağmen geri yayılım algoritması ile tek gizli katmana sahip bu yapay sinir ağı modeli incelenen diğer yöntemlerden daha etkili olmuştur.

Yapılan testlerin sonuçları YSA'nın tahminleme için etkin bir çözüm olduğunu göstermektedir. Ancak prototip uygulama esnasında hafta içi ve hafta sonu günlerinde talebin farklı bir dağılım gösterdiği görülmüştür. Bu nedenle hafta içi günlere ilişkin talep verileriyle hafta içi günlerin, hafta sonu talep verileriyle hafta sonu günlerin tahmin edilmesi gerektiği sonucuna varılmıştır. Bu nedenle prototip uygulamadan sonra esas uygulama için 2017 yılının Eylül ayına ait bir aylık veri ele alınarak hafta içi günleri için ayrı, hafta sonu günleri için ayrı talep tahmini YSA'ları oluşturulması planlanmış ve uygulanmıştır.

4.10. HATLAR İÇİN KAPASİTE ve TALEP DÜZEYLERİNİ DİKKATE ALARAK OPTİMUM SEFER SIKLIĞININ BELİRLENMESİNDE KULLANILAN YAKLAŞIM

Bu bölümde benzer çalışmalarda (Alp, 2008; Uludağ, 2010; Deri, 2012) olduğu gibi optimum sefer sıklığını belirlemek üzere doğrusal hedef programlama modeli kurularak ve geliştirilen yaklaşım ile çözülmüştür.

Geliştirilen algoritma 3. Bölümde “Geliştirilen algoritmik yaklaşım” başlığı altında açıklanmıştır. Geliştirilen algorithmada çeşitli matematiksel modeller kullanılarak optimum sefer sıklığı belirlenmiştir.

4.10.1. Hatlar İçin Kapasite ve Zaman Kısıtları Dikkate Alınarak Optimum Sefer Sıklığının Belirlenmesi İçin Geliştirilen Modeller

Geliştirilen modelde 3. bölümdeki algoritma için amaç denklemde sadece negatif sapmaların bulunduğu bir amaç denklem, hem negatif hem pozitif sapmaların eşit ağırlıklı olduğu bir amaç denklem ve negatif sapmalara daha fazla önem veren ağırlıklı bir model kullanılarak optimum sefer sıklığı belirlenmiştir.

İlk matematiksel modelde sadece eksik kapasite ve eksik zamanı gösteren negatif sapmaları içeren bir amaç denklem minimize edilmeye çalışılmaktadır. Amaç denklem denklem 55’de gösterilmiştir.

$$\text{Model 1: Min } z = \sum d_1^- + d_K^- + d_S^- \quad \text{Denklem 55}$$

İkinci matematiksel modelde hem eksik hem de fazla kapasite ve zamanı gösteren negatif ve pozitif sapmaları içeren eşit ağırlıklı bir amaç denklem minimize edilmeye çalışılmaktadır. Amaç denklem denklem 56’da gösterilmiştir.

$$\text{Model 2: Min } z = \sum d_1^- + d_1^+ + d_K^- + d_K^+ + d_S^- + d_S^+ \quad \text{Denklem 56}$$

Üçüncü modelde ise negatif sapmaları öncelikli olarak dikkate alan bir amaç denklem kullanılmıştır. Amaç denklem denklem 57’de gösterilmiştir.

$$\text{Model 3: Min } z = \sum (d_1^- + d_K^- + d_S^-) \times w_{\text{Negatif}} + (d_1^+ + d_K^+ + d_S^+) \times w_{\text{Pozitif}} \quad \text{Denklem 57}$$

Pozitif ve negatif ağırlık katsayıları ($w_{Negatif}, w_{Pozitif}$) karar vericinin hangi değişkenlerin minimize edilmesine daha fazla önem verdiğini gösterir. Negatif sapmalar eksik kapasite ve eksik zamanı ifade ettiğinden bu değerlerin sıfır olması gerektiği düşüncesi ile $w_{Negatif}=1.000$, $w_{Pozitif}=1$ olarak düşünülmüştür.

4.10.2. Hatlar İçin Kapasite ve Zaman Kısıtları ile Durakta Bekleme Süreleri Dikkate Alınarak Optimum Sefer Sıklığının Belirlenmesi İçin Geliştirilen Modeller

Durakta bekleme sürelerinin bir toplu taşıma sisteminin kalite algılamasında önemli bir payı vardır. Bu nedenle optimum sefer sıklığını belirlerken mutlaka durakta bekleme süreleri de dikkate alınmalıdır. Bekleme sürelerini modele eklerken Marquier ve Ceder'in yaklaşımı kullanılmıştır. Otobüs gelişleri arasındaki sürelerin dağılımı Matlab R2014 yazılımının "Distribution Fitting" uygulaması ile test edilmiş ve verilerin Poisson dağılımına uygun olduğu görülmüştür. Önceki başlıkta anlatılan her üç modele bekleme süresi olarak ortalama seferler arası süre eklenerek kullanılmıştır. Modellerdeki amaç denklemler denklem 58, denklem 59 ve denklem 60'da gösterilmiştir.

$$\text{Model 4: Min } z = \sum d_1^- + d_K^- + d_S^- + \frac{S_i}{x_i} \quad \text{Denklem 58}$$

$$\text{Model 5: Min } z = \sum d_1^- + d_1^+ + d_K^- + d_K^+ + d_S^- + d_S^+ + \frac{S_i}{x_i} \quad \text{Denklem 59}$$

$$\text{Model 6: Min } z = \sum (d_1^- + d_K^- + d_S^-) \times w_{Negatif} + (d_1^+ + d_K^+ + d_S^+) \times w_{Pozitif} + \frac{S_i}{x_i} \times w_{bekleme} \quad \text{Denklem 60}$$

Yolcuların durakta bekleme süreleri karar vericiler için ne kadar önem taşıyorsa $w_{bekleme}$ ağırlık katsayısı o derecede yüksek seçilmelidir. Bu değişkeni fazla önemsemeyen karar vericiler 1 veya 2 gibi küçük değerler uygulayabilirler. Bu değişkeni çok önemseyen karar vericiler ise 500 gibi büyük bir değer de seçebilirler.

4.10.3. Hatlar İçin Kapasite, Zaman Kısıtları ve Durakta Bekleme Süreleri ile Araç İçinde m²'ye Düşen Yolcu Sayısı Dikkate Alınarak Optimum Sefer Sıklığının Belirlenmesi İçin Geliştirilen Modeller

Toplu taşımada kalite algılamasını etkileyen unsurlardan birisi de araçtaki yolcuların sıkışıklık durumudur. Sıkışıklık durumunun ölçümünde yolcu sayısı/m² (pax/m²) ölçütü kullanılmaktadır (Batarce vd., 2015; Qin, 2014; Varghese ve Adhvaryu, 2016; Tirachini, 2012). Çok sayıda yolcu bulunan bir otobüste kişi başına düşen alan azalacağından yolcular sıkışıklık yaşar ve rahatsız olurlar. Bu durum yolcuların birbirleriyle fiziksel temaslarını arttırıp, hareket etmelerini zorlaştırdığı gibi yan kesicilik, taciz olaylarına da sebep olabilir ve bu nedenlerle yolcuların kalite algısını azaltır. Ayaktaki yolcu sıklığının olması gereken seviye ülkeden ülkeye değişmektedir. Örneğin Avrupa ve Avustralya için 4 yolcu/m² (Diec vd., 2010) referans iken, bu değer ABD'de 5 yolcu/m² (TRB, 2006), Çin'de ise 8 yolcu/m²'ye (AQSIQ 2004'den aktaran Li ve Hensher, 2013: 109) yükselmektedir. Bu nedenle hattaki körüklü ve solo otobüs sayısına bağlı olarak metrekareye düşen yolcu sayısı - MDYS denklem 61'deki şekilde hesaplanmakta ve denklem 62, denklem 63 ve denklem 64'deki gibi modellere eklenebilmektedir.

$$MDYS = \frac{(Talep/x_i \times (N_K/(N_K+N_S)))}{Körüklü Otobüsün Alanı} + \frac{(Talep/x_i \times (N_S/(N_K+N_S)))}{Solo Otobüsün Alanı} \quad \text{Denklem 61}$$

$$\text{Model 7: Min } z = \sum d_1^- + d_K^- + d_S^- + \frac{S_i}{x_i} + MDYS \quad \text{Denklem 62}$$

$$\text{Model 8: Min } z = \sum d_1^- + d_1^+ + d_K^- + d_K^+ + d_S^- + d_S^+ + \frac{S_i}{x_i} + MDYS \quad \text{Denklem 63}$$

$$\text{Model 9: Min } z = \sum (d_1^- + d_K^- + d_S^-) \times w_{\text{Negatif}} + (d_1^+ + d_K^+ + d_S^+) \times w_{\text{Pozitif}} + \frac{S_i}{x_i} \times w_{\text{bekleme}} + MDYS \times w_{MDYS} \quad \text{Denklem 64}$$

Denklem 61'de körüklü ve solo otobüsün alanı ayakta duran yolcuların kullanabileceği alanlardır. Bu bölümler koridorları, oturaklar arasında bırakılan boş bölümleri ve kapı önündeki boşlukları kapsamaktadır.

Otobüste m^2 'ye düşen yolcu sayısı karar vericiler için çok önemli ise w_{MDYS} için 500 gibi büyük değerler kullanılabilir. Bu değişkene fazla önem vermeyen karar vericiler ise 1 veya 2 gibi küçük değerler kullanabilirler.

4.10.4. Hatlar İçin Kapasite, Zaman Kısıtları, Durakta Bekleme Süreleri, Araç İçinde m^2 'ye Düşen Yolcu Sayısı ve Sefer Maliyeti Dikkate Alınarak Optimum Sefer Sıklığının Belirlenmesi için Geliştirilen Modeller

Toplu taşıma planlamasında yolcuların kalite algısı kadar önemli olan bir diğer değişken ulaşım maliyetidir. Bu nedenle modellere ulaşım maliyeti de eklenmelidir. Yolcu kalite algısı bakımından bekleme süresinin azaltılması ve kişi başına düşen alanın arttırılabilmesi için daha fazla sefer konulması gerekir. Ancak konulan her sefer hattın toplam işletme maliyetini arttıracaktır. Bu nedenle maliyetin de minimize edileceği modeller kurulmalıdır. Modeli basitleştirmek amacıyla sadece yakıt maliyeti dikkate alınmıştır. Ortaya çıkan modeller denklem 66, denklem 67 ve denklem 68'de gösterilmiştir. 2017 yılında EMO İzmir Şubesinin ESHOT Genel Müdür Yardımcısı olan Fazıl Ölçer ile yaptığı röportajda ortalama mazot tüketiminin 2016 yılı için 0,53 lt/km olduğunu söylemiştir (EMO İzmir Şubesi, 2017: 29). Mazot maliyeti denklem 65'e göre hesaplanmaktadır.

$$Maliyet = Fiyat \times Mesafe \times 0,53 \quad \text{Denklem 65}$$

$$\text{Model 10: Min } z = \sum d_1^- + d_K^- + d_S^- + \frac{S_i}{x_i} + MDYS + \text{Maliyet} \quad \text{Denklem 66}$$

$$\text{Model 11: Min } z = \sum d_1^- + d_1^+ + d_K^- + d_K^+ + d_S^- + d_S^+ + \frac{S_i}{x_i} + MDYS + \text{Maliyet} \quad \text{Denklem 67}$$

$$\text{Model 12: Min } z = \sum (d_1^- + d_K^- + d_S^-) \times w_{\text{Negatif}} + (d_1^+ + d_K^+ + d_S^+) \times w_{\text{Pozitif}} + \frac{S_i}{x_i} \times w_{\text{bekleme}} + MDYS \times w_{MDYS} + \text{Maliyet} \times w_{\text{Maliyet}} \quad \text{Denklem 68}$$

Maliyet değişkeni karar vericiler için çok öneme sahipse w_{Maliyet} ağırlık katsayısı 500 gibi büyük değerler seçilebilir. Karar vericilere göre maliyet kalite algısından daha az öneme sahipse bu değer 1 veya 2 gibi küçük değerler alabilir. Ağırlık katsayılarının farklı değerleri için optimum çözümdeki değişim incelenmelidir. Böyle bir inceleme duyarlılık analizi bölümünde gösterilmiştir.

Bekleme süresini dikkate alan denklem 58’de gösterilen Modelde bekleme sürelerini minimize ederken aynı zamanda otobüste kişi başına düşen alanında arttığı görülmektedir. Bu nedenle denklem 68 ile gösterilen 12. Modelde hem bekleme süresinin hem de kişi başına düşen alanın modelde yer alması, daha fazla sefer konulması yönünde iki defa baskı oluşturmaktadır. Otobüs işletmesi bekleme süresini dikkate almanın zaten kişi başına düşen alanı arttıracığından bu değişkene modelde ihtiyaç olmadığını, maliyetleri lüzumsuz şekilde arttırdığını düşünebilir. Bu nedenle denklem 68’da gösterilen model 12’den kişi başına düşen alan değişkeni çıkartılarak denklem 69’da gösterilen model oluşturulmuştur.

$$\text{Model 13: Min } z = \sum (d_1^- + d_K^- + d_S^-) \times w_{\text{Negatif}} + (d_1^+ + d_K^+ + d_S^+) \times w_{\text{Pozitif}} + \frac{S_1}{X_1} \times w_{\text{bekleme}} + \text{Maliyet} \times w_{\text{Maliyet}} \quad \text{Denklem 69}$$

4.10.5. Model 13’de MDYS için Sistem Kısıtı Konulan Model

Model 13’deki metrekaareye düşen yolcu sayısı amaç denklemden çıkartılmış onun yerine bir sistem kısıtı getirilmiştir. Bunun için yapılan literatür araştırmasında m²’ye düşen yolcu sayısının üst sınırı tespit edilmeye çalışılmıştır. Avrupa’da referans değeri olarak 4 yolcu/m² kullanılıyor olsa da bu değer konforlu bir taşımayı ifade etmemektedir. Li ve Hensher 2013’de yayınlanan makalelerinde yolcu başına alan (m²/yolcu) değerlerini ve kalabalıklık durumlarını göstermişlerdir. Bu değerler yolcu/m² değerlerine de dönüştürülerek Tablo 22’de sunulmuştur.

Tablo 22: Kalabalıklık Ölçüsü Olarak m²/yolcu ve yolcu/m² Değerleri

m ² /yolcu	yolcu/m ²	Durum
> 1,0	1,0<	Her yolcu yalnız oturuyor
0,76 – 1,0	1,0 – 1,316	Yolcu oturacağı yeri seçebilir
0,51 – 0,75	1,33 – 1,96	Bütün yolcular oturuyor
0,36 – 0,50	2,0 – 2,77	Ayaktaki yolcular konforlu yolculuk yapıyorlar
0,20 – 0,35	2,86 – 5	Maksimum çizelge yükü
<0,20	>5	Aşırı Kalabalık

Tablo 22’ye göre ayaktaki yolcuların konforu bakımından yolcu/m² değeri 2,86’dan küçük olmalıdır. Bu nedenle sistem kısıtında metrekaareye düşen yolcu

sayısının 2,86'dan küçük olması koşulu tanımlanmıştır. Oluşturulan amaç denklem denklem 70'de, kısıt ise denklem 71'de gösterilmiştir.

$$\text{Model 14: Min } z = \sum (d_1^- + d_K^- + d_S^-) \times w_{\text{Negatif}} + (d_1^+ + d_K^+ + d_S^+) \times$$

$$w_{\text{Pozitif}} + \frac{S_i}{X_i} \times w_{\text{bekleme}} + \text{Maliyet} \times w_{\text{Maliyet}} \quad \text{Denklem 70}$$

Sistem Kısıtı:

$$\sum \text{MDYS}_i < 2,86 \quad \text{Denklem 71}$$

Bu sistem kısıtı yardımıyla maliyetin sefer sayısını azaltma yönündeki baskısına sınırlama getirmek amaçlanmıştır.

4.10.6. Optimum Sefer Sıklığı Optimizasyon Modellerinin 802 Nolu Egekent Aktarma - Konak Hattı için Karşılaştırılması

Yukarıda açıklanan modellerden 802 nolu Egekent Aktarma – Konak hattının hafta sonu gidiş yönü için hesaplanan optimum sefer sıklıkları ve hat performans ölçütleri Tablo 23'de gösterilmiştir.

Tablo 23: Optimum Sefer Sıklığı Optimizasyon Modellerinin Birbiri ve Hattın Mevcut Çizelgesiyle Karşılaştırılması

	Sefer Sıklığı	Sefer Başına Yolcu Sayısı	Bekleme	Maliyet	Yolcu/m ²	Atıl Kapasite	Eksik Kapasite	Atıl Zaman Körüklü	Eksik Zaman Körüklü	Atıl Zaman Solo	Eksik Zaman Solo	Z
Mevcut Durum	9	123	3,18	381	3,18	217,5	0	10,45	0	0,55	0	-
Model1	8	139	7,5	338	3,6	70	0	11,40	0	0,60	0	0,0
Model2	8	139	7,5	338	3,6	70	0	11,40	0	0,60	0	82,0
Model3	8	139	7,5	338	3,6	70	0	11,40	0	0,60	0	98,4
Model4	20	56	3,0	846	1,5	1.840	0	0	0	0,00	0	3,0
Model5	8	139	7,5	338	3,6	70	0	11,40	0	0,60	0	89,5
Model6	14	123	6,7	381	2,2	217	0	10,4	0	0,55	0	3.724,6
Model7	20	56	3,0	846	1,5	1.840	0	0	0	0,00	0	4,5
Model8	8	139	7,5	338	3,6	70	0	11,40	0	0,60	0	93,1
Model9	18	58	3,2	804	1,6	1.693	0	0,95	0	0,05	0	5.153,0
Model10	8	139	7,5	338	3,6	70	0	11,40	0	0,60	0	349,4
Model11	7	159	8,6	296	4,1	0	77,5	12,35	0	0,65	0	399,2
Model12	15	69	3,8	677	2,0	1.250	0	3,80	0	0,20	0	7.220,7
Model13	11	139	5,4	465	2,7	512,5	0	8,55	0	0,45	0	5.294,2
Model14	11	101	5,4	465	2,7	512,5	0	8,55	0	0,45	0	5.294,2

Tablo 23’de 1, 2, 3, 5, 8,10. modellerde optimum sefer sıklığının 8 olarak hesaplandığı görülmüştür. Bulunan sefer sıklığı ESHOT’un uyguladığı sefer sıklığına yakındır. 1. modelde sadece negatif sapmalar, 2,5 ve 8. modellerde pozitif ve negatif sapmalar ile diğer değişkenler eşit ağırlıklı; 3. modelde pozitif ve negatif sapmalar ağırlıklı olarak; 10. Modelde ise negatif sapmalar, bekleme süresi, kişi başına düşen alan ve maliyet değişkenleri eşit ağırlıklı olarak hesaba katılmaktadır. Model 4 ve model 7’de optimum sefer sıklığı 20 olarak hesaplanmıştır. Model 4’te negatif sapmalar ve bekleme süresi; model 7’de negatif sapmalar, bekleme süresi ve m^2 ’ye düşen yolcu sayısı eşit ağırlıklı olarak hesaba katılmaktadır. Hattın mevcut çizelgesine göre bu modellerde bekleme süresi ve m^2 ’ye düşen yolcu sayısı daha düşük, maliyet daha yüksektir. Bu modellerde atıl kapasite en yüksek düzeyde iken eksik zaman yoktur. Model 6’da optimum sefer sıklığı 14 olarak hesaplanmıştır. Bu modelde negatif ve pozitif sapmalar ve bekleme zamanı ağırlıklı olarak hesaba katılmaktadır. Hattın mevcut çizelgesine göre bekleme süresi ve m^2 ’ye düşen yolcu sayısı daha az, maliyet daha fazla olacaktır. Mevcut çizelgeye göre atıl kapasite daha fazla, atıl zaman daha azdır. Model 9’da optimum sefer sıklığı 18 olarak hesaplanmıştır. Bu modelde negatif ve pozitif sapmalar ile bekleme süresi ve m^2 ’ye düşen yolcu sayısı ağırlıklı olarak hesaba katılmaktadır. Hattın mevcut çizelgesine göre bekleme süresi ve m^2 ’ye düşen yolcu sayısı daha az, maliyet daha fazla olacaktır. Mevcut çizelgeye göre atıl kapasite daha fazla, atıl zaman daha azdır. Model 11’de optimum sefer sıklığı 7 olarak hesaplanmıştır. Bu modelde bütün değişkenler eşit ağırlıklı olarak hesaba katılmaktadır. Mevcut çizelgeye göre bekleme süresi daha uzun, m^2 ’ye düşen yolcu sayısı daha fazla ve maliyet daha düşüktür. Mevcut çizelgeye göre atıl kapasite daha az, atıl zaman daha fazladır. Model 12’de optimum sefer sıklığı 15 olarak hesaplanmıştır. Bu modelde birbiriyle çelişen bütün değişkenler ağırlıklı olarak hesaba katılmaktadır. Mevcut çizelgeye göre bekleme süresi daha kısa, m^2 ’ye düşen yolcu sayısı daha az ve maliyet daha yüksektir. Mevcut çizelgeye göre atıl kapasite daha yüksek, atıl zaman daha düşüktür. Model 13’de negatif ve pozitif sapmalar ile bekleme süresi ve maliyet hesaba katılmaktadır. Model 13’te optimum sefer sıklığı 11 olarak hesaplanmıştır. Model 14’te ayaktaki yolcuların daha konforlu bir yolculuk yapılabilmesi için m^2 ’ye düşen yolcu sayısının 2,86’dan küçük olması şartı sağlanmaktadır. Bu koşulu sağlayan, maliyet ve bekleme süresi arasında denge noktasını oluşturan sefer sayısı 11 olarak hesaplanmıştır.


Elde edilen bu sonuçlar değerlendirilerek sapmaların ve diğer değişkenlerin ağırlıklı olarak hesaba katıldığı model 3, model 6, model 9, model 12, model 13 ve model 14'ün daha sağlıklı sonuç verme potansiyeline sahip olduğu anlaşılmıştır. Bu nedenle esas uygulamada sadece bu altı model test edilecektir. Bu modeller ile çalışırken karar mercileri ağırlık katsayılarını değiştirmek suretiyle istedikleri değişkenlerin daha fazla dikkate alınmasını sağlayabilmektedir. Her değişken için ağırlık katsayıları duyarlılık analizi ile tespit edilebilir. Bu esnek yapıları nedeniyle ağırlık katsayısı içeren modeller seçilmiştir.

4.10.7. Duyarlılık Analizi

4.10.7.1. Pozitif Sapmalar Ağırlık Katsayısı İçin Duyarlılık Analizi

Pozitif sapmalar için kullanılan ağırlık katsayısının hesaplanan sefer sıklığına ve diğer değişkenlere etkilerini belirlemek amacıyla diğer değişkenler sabit tutulurken (Talep=1.110; Körüklü otobüs sayısı=19; Solo otobüs sayısı=1; Hat uzunluğu=13,3 km; $w_{negatif}=1.000$; $w_{bekleme}=500$; $w_{maliyet}=2,5$; $w_{MDYS}=500$) bu ağırlık katsayısı [0 - 10] aralığında 0,1'er artışlarla değiştirilmiştir. Bu şekilde ağırlık katsayısını değiştirdikçe model 12'nin hesapladığı optimum sefer sıklıkları ve bekleme süreleri Şekil 32'de, maliyet ve m^2 'ye düşen yolcu sayısı ise Şekil 33'de gösterilmiştir.


Şekil 32: Pozitif Sapmaların Ağırlık Katsayısının Sefer Sıklığına ve Bekleme Sürelerine Etkisi



Şekil 32'de pozitif sapmaların katsayısı artarken optimum sefer sıklığı kademeli olarak azalmaktadır. Katsayı arttıkça yolcu bekleme süresi kademeli olarak artmaktadır. Başlangıçta 20 olan çözüm $w_{pozitif}$ değeri 0,3 (19); 0,5 (18); 0,6 (17); 0,7 (16); 0,9 (15); 1,1 (14); 1,4 (13); 1,7 (12); 2,1 (11); 2,9 (10) ve 5,7 (8) olduğunda değişmektedir. Bu durum Şekil 33'de görüldüğü gibi maliyeti azalırken m^2 'ye düşen yolcu sayısı artmaktadır. Bekleme süresinin ve m^2 'ye düşen yolcu sayısının artması

kalite algısı bakımından iyi değildir. Ancak maliyetin azalması da dikkate alınmalıdır. Bu nedenle orta düzeyde pozitif sapma katsayısı daha uygun olabilir. Esas uygulamada bu değer 1,2 olarak uygulanmıştır.

Şekil 33: Pozitif Sapmaların Ağırlık Katsayısının Maliyet ve m²'ye Düşen Yolcu Sayısına Etkisi




4.10.7.2. Negatif Sapmalar Ağırlık Katsayısı için Duyarlılık Analizi

Negatif sapmalar için kullanılan ağırlık katsayısının hesaplanan sefer sıklığına ve diğer değişkenlere etkilerini belirlemek amacıyla diğer değişkenler sabit tutulurken (Talep=1.110; Körüklü otobüs sayısı=19; Solo otobüs sayısı=1; Hat uzunluğu=13,3 km; $w_{\text{pozitif}}=1,2$; $w_{\text{bekleme}}=500$; $w_{\text{maliyet}}=2,5$; $w_{\text{MDYS}}=500$) bu ağırlık katsayısı [0-1.000.000] aralığında 10'ar artışlarla değiştirilmiştir. Yapılan analizde katsayı ne olursa olsun negatif sapmaların sıfır olması nedeniyle sonuca etkisi olmadığı görülmüştür. Buna rağmen negatif sapmaların önlenmesini garanti etmek amacıyla bu katsayı 1.000 olarak uygulanmıştır.

4.10.7.3. Durakta Bekleme Süresi Ağırlık Katsayısı için Duyarlılık Analizi


Durakta bekleme süresi için kullanılan ağırlık katsayısının hesaplanan sefer sıklığına ve diğer değişkenlere etkilerini belirlemek amacıyla diğer değişkenler sabit tutulurken (Talep=1.110; Körüklü otobüs sayısı=19; Solo otobüs sayısı=1; Hat uzunluğu=13,3 km; $w_{\text{pozitif}}=1,2$; $w_{\text{negatif}}=1.000$, $w_{\text{maliyet}}=2,5$, $w_{\text{MDYS}}=500$) bu ağırlık katsayısı [0 – 2.000] aralığında 50'şer artışlarla değiştirilmiştir. Bu şekilde ağırlık katsayısını değiştirdikçe model 12'nin hesapladığı optimum sefer sıklıkları ve bekleme süreleri Şekil 34'de, maliyet ve kişi başına düşen alanlar ise Şekil 35'te gösterilmiştir.

Şekil 34: Yolcu Bekleme Süresi Ağırlık Katsayısının Sefer Sıklığına ve Bekleme Sürelerine Etkisi



Şekil 34'te yolcu bekleme süresi katsayısının artması nedeniyle bekleme süresinin baskısı ağır gelmekte ve sefer sayısı kademeli olarak arttırılmaktadır. Katsayı arttıkça sefer yolcu bekleme süresini kısaltmak için sefer sayısı arttırılacaktır. Başlangıçta 10 olan çözüm w_{bekleme} değeri 100 (11), 250 (12), 350 (13), 450 (14), 600 (15), 700 (16), 850 (17), 1.000 (18), 1.200 (19) ve 1.350 (20) olduğunda değişmektedir. Bu durum şekil 35'te görüldüğü gibi maliyeti arttırırken m^2 'ye düşen yolcu sayısını azaltmaktadır. Bekleme süresinin ve m^2 'ye düşen yolcu sayısının azalması kalite algısı bakımından daha iyi olacaktır. Ancak maliyet artışının işletme açısından sakıncalı olabileceği unutulmamalıdır. Bu nedenle orta düzeyde bekleme süresi katsayısı daha uygun olabilir. Esas uygulamada bu değer 600 olarak uygulanacaktır.


Şekil 35: Yolcu Bekleme Süresi Katsayısının Maliyete ve m^2 'ye Düşen Yolcu Sayısına Etkisi



4.10.7.4. Maliyet Ağırlık Katsayısı için Duyarlılık Analizi


Maliyet için kullanılan ağırlık katsayısının hesaplanan sefer sıklığına ve diğer değişkenlere etkilerini belirlemek amacıyla diğer değişkenler sabit tutulurken (Talep=1.110; Körüklü otobüs sayısı=19; Solo otobüs sayısı=1; Hat uzunluğu=13,3 km; $w_{pozitif}=1,2$; $w_{negatif}=1.000$; $w_{bekleme}=600$; $w_{KBDA}=500$) bu ağırlık katsayısı $[0,0 - 10,0]$ aralığında 0,1 artışlarla değiştirilmiştir. Bu şekilde ağırlık katsayısını değiştirdikçe model 12'nin hesapladığı optimum sefer sıklıkları ve bekleme süreleri Şekil 36'da, maliyet ve m^2 'ye düşen yolcu sayıları ise Şekil 37'de gösterilmiştir.

Şekil 36: Maliyet Ağırlık Katsayısının Sefer Sıklığına ve Bekleme Sürelerine Etkisi



Şekil 36'da maliyet katsayısının artması nedeniyle maliyet baskısı ağır gelmekte ve sefer sayısı kademeli olarak azalmaktadır. Başlangıçta 19 olan çözüm $w_{maliyet}$ değeri 0,2 (18); 0,7 (17); 1,3 (16); 2,0 (15), 2,8 (14), 3,9 (13), 5,2 (12), 6,7 (11) ve 9,4 (10) olduğunda değişmektedir. Sefer sıklığı azaldıkça doğal olarak yolcuların durakta bekleme süreleri artmaktadır. Bu durum kalite algısını olumsuz yönde etkilemektedir.

Şekil 37: Maliyet Ağırlık Katsayısının Maliyete ve m^2 'ye Düşen Yolcu Sayısına Etkisi




Şekil 37’de soldaki şekilde maliyet katsayısı arttıkça m^2 ’ye düşen yolcu sayısı artmaktadır. Bu durum daha sıkışık ve rahatsız bir seyahat ortamı oluşturduğundan olumsuz kalite algısına neden olmaktadır. Ağırlık katsayısı arttıkça maliyet azalmaktadır ancak bekleme süresinin ve m^2 ’ye düşen yolcu sayısının artması nedeniyle kalite algısı olumsuz yönde değişmektedir. Bu nedenle esas uygulamada orta düzeyde maliyet baskısı yapan 3,0 değeri kullanılacaktır.

4.10.7.5. m^2 ’ye Düşen Yolcu Sayısı Ağırlık Katsayısı için Duyarlılık Analizi

m^2 ’ye düşen yolcu sayısı için kullanılan ağırlık katsayısının hesaplanan sefer sıklığına ve diğer değişkenlere etkilerini belirlemek amacıyla diğer değişkenler sabit tutulurken (Talep=1.110; Körüklü otobüs sayısı=19; Solo otobüs sayısı=1; Hat uzunluğu=13,3 km; $w_{pozitif}=1,2$, $w_{negatif}=1.000$, $w_{bekleme}=600$, $w_{maliyet}=3,0$) bu ağırlık katsayısı [0 – 5.000] aralığında 50’şer artışlarla değiştirilmiştir. Bu şekilde ağırlık katsayısını değiştirdikçe model 12’nin hesapladığı optimum sefer sıklıkları ve bekleme süreleri Şekil 38’de, maliyet ve m^2 ’ye düşen yolcu sayıları ise Şekil 39’da gösterilmiştir.


Şekil 38: m^2 ’ye Düşen Yolcu Sayısı Ağırlık Katsayısının Sefer Sıklığı ve Yolcuların Bekleme Süresine Etkisi



Şekil 38’de m^2 ’ye düşen yolcu sayısı değişkeninin ağırlık katsayısı arttıkça optimum sefer sıklığının kademeli olarak artış, yolcuların bekleme süresinin ise kademeli olarak düşüş trendi izlediği görülmektedir. Başlangıçta optimum sefer sıklığı 11 iken çözümün w_{MDYS} değerinin 100 (12), 250 (13), 400 (14), 550 (15), 750 (16), 900 (17), 1.100 (18), 1.300 (19), 1.500 (20) değerlerinde değiştiği görülmektedir. Optimum sefer sıklığı arttıkça m^2 ’ye düşen yolcu sayılarının azaldığı

ve maliyetin arttığı Şekil 39’da görülebilmektedir. Bekleme süresinin ve m^2 ’ye düşen yolcu sayılarının düşük olması istenen bir durum olsa da maliyet unsuru da dikkate alınmalıdır. Bu katsayı ne kadar yüksek olursa o kadar fazla sefer sıklığı hesaplanacaktır. Bu da artan maliyet anlamına gelir. Bu nedenle kişi başına düşen alan ağırlık katsayısını düşük tutarak esas uygulamada 800 değeri kullanılacaktır.

Şekil 39: m^2 ’ye Düşen Yolcu Sayısı Ağırlık Katsayısının Maliyete ve m^2 ’ye Düşen Yolcu Sayısına Etkisi



4.11. OPTİMUM SEFER SIKLIKLARININ TESPİTİ İÇİN GELİŞTİRİLEN GENETİK ALGORİTMA

Genetik algoritmalar NP-zor sınıfı problemlerin çözümünde optimal sonuç veren evrim teorisine dayalı popülasyon tabanlı optimizasyon algoritmalarıdır. Optimum sefer sıklığı problemi her hat ayrı ayrı incelendiğinde polinomial zor problem sınıfındadır. Her hattın hafta içi ve hafta sonu için gidiş ve dönüş yönünde sefer sıklıkları belirlenmelidir. 10 hattın hafta içi ve hafta sonu gidiş ve dönüş yönündeki optimum sefer sıklıklarının belirlenmesi non-polinomial zor sınıfında bir probleme dönüşür. Bu nedenle optimizasyon için genetik algoritmaların kullanımı mümkündür. Ancak genetik algoritmalar optimum sonucu garanti etmez optimuma yakın bir sonuç verirler.

4.11.1. Kodlama ve Genetik Yapı

Algoritma geliştirilirken permütasyon kodlama sistemi tercih edilmiştir. Her bir gen bir hattın hafta içi veya hafta sonu gidiş veya dönüş yönündeki sefer sıklığı bilgisini taşımaktadır. Her gen aynı zamanda hattın optimizasyon parametrelerini de

(Hattın km cinsinden uzunluğu, hatta kullanılan körüklü ve solo otobüs sayısı, ortalama seyahat süresi vb.) içerir. Her hat için hafta sonu ve hafta içi gidiş ve dönüş yönleri için ayrı genlere ihtiyaç olduğundan 4 gen oluşturulmuştur.

4.11.2. Uygunluk Fonksiyonu

Problemi formüle ederken denklem 69 ile gösterilen model 13 amaç denklem olarak kullanılmıştır. Bu amaç denklem ile elde edilen puanın minimizasyon problemi olması nedeniyle dönüştürülerek uygunluk formuna sokulması gereklidir. Denklem 38’de gösterildiği gibi bireyin amaç denklem puanı popülasyonun en yüksek amaç denklem puanından çıkartılarak uygunluk formuna dönüştürülmüştür. Bireylerin uygunluk değerleri bu şekilde hesaplandığında en düşük amaç denklem değerine sahip olan bireylerin eşleşme havuzuna seçilme olasılığı arttırılmış olur. Böylece minimum amaç denklem değerine ulaşılabilir.

$$Z = \sum (d_1^- + d_K^- + d_S^-) \times 1000 + (d_1^+ + d_K^+ + d_S^+) \times 1,2 + \frac{s_i}{x_i} \times 600 + \text{Maliyet} \times 3$$

4.11.3. Başlangıç Popülasyonunun Oluşturulması

Başlangıç popülasyonu oluşturulurken, inceleme süresi üst sınır olacak şekilde rastgele bir değer genlere atanmaktadır. Mesela 60 dakikalık zaman dilimi için optimum sefer sıklığı hesaplanacaksa genler [1-59] aralığında rastgele bir değer alabilir. Daha sonra bu değer için (x), bir küçüğü (x-1) ve bir büyüğü (x+1) için uygunluk değerleri hesaplanır ve en küçük uygunluk değerine sahip değer gene aktarılır. Bu şekilde değer atanan genler bireyin rastgele oluşturulmasını sağlar.


4.11.4. Seçim ve Üreme Operatörü

Genetik algoritma modelinde en iyi bireylerin eşleşme havuzuna girmesini sağlayan rulet tekerleği seçimi kullanılmıştır. Ayrıca en iyi bireyin çaprazlama ve mutasyon işlemleri esnasında kaybedilmemesi için popülasyondaki en iyi birey korunarak sonraki nesile aktarılmaktadır.

4.11.5. Çaprazlama Operatörü

Bu genetik algoritma modelinde tek noktalı permütasyon çaprazlama operatörü kullanılmıştır. Bu operatörün çalışması Şekil 40’da gösterilmiştir.

Şekil 40: Tek Noktalı Permütasyon Çaprazlama Operatörünün İşleyişi



Bu operatörde önce rastgele bir çaprazlama noktası belirlenir. Bu noktaya kadar ebeveyn bireylerden birisindeki genler çocuğa olduğu gibi aktarılır. Bu noktadan itibaren genler ikinci ebeveynden alınır. Bu şekilde iki ebeveynden bir çocuk birey oluşturulur. Aynı işlem bu kez ilk önce ikinci ebeveynden gen aktarımına başlayarak tekrarlanır ikinci bir çocuk birey oluşturulur.

4.11.6. Mutasyon Operatörü

Mutasyon işlemi için 3.5 numaralı “Geliştirilen algoritmik yaklaşım” başlığı altında açıklanan yaklaşıma benzeyen tek noktalı mutasyon operatörü kullanılmıştır. Bu operatörde genin mevcut içeriğine bakılmaksızın [1 - 60] aralığında rastgele bir tamsayı seçilir. Bu değer, bir küçük değer ve bir büyük değere ilişkin amaç denklem değeri hesaplanır. Bu üç değerden hangisi için hesaplanan amaç denklem değeri daha düşükse o değer genin değeri olarak belirlenir.

Önceki paragrafta açıklanan probleme özel tek noktalı mutasyon operatörünün aynı kromozoma istenilen sayıda tekrar uygulanması yoluyla çok noktalı mutasyon operatörü de geliştirilmiş ve denenmiştir. Çok noktalı mutasyon operatörü ile daha iyi sonuçlar alındığı gözlenmiştir.

4.12. ALGORİTMANIN UYGULANMASI

Prototip uygulama neticesinde istenilen performansı sağlayan algoritmalar daha sonra 2 Ekim – 31 Ekim 2017 tarih aralığında toplanan akıllı kart ve GPS verilerine en yoğun 10 Konak hattı için uygulanmıştır. Algoritmanın farklı kısımları için elde edilen sonuçlar sırasıyla ilerleyen başlıklarda verilmiştir.

4.12.1. Biniş Duraklarından İniş Duraklarının Tahmini Algoritmasının Performansı

Prototip uygulamada geliştirilen Trépanier ve arkadaşlarının önerdiği yolculuk zincirleme yöntemi ve Diker'in rastgele atama tahmin yöntemi ve son durağa atama yöntemlerini içeren algoritma 2 Ekim – 31 Ekim 2017 tarih aralığı için 10 Konak hattına uygulanmış ve biniş duraklarından iniş durakları tahmin edilmiştir. Bunun için Konak hatlarının toplam biniş sayıları tespit edilmiş ve en yüksek değerlere sahip olan ilk 10 hat uygulama için seçilmiştir. Hatların Biniş sayıları Tablo 24'de gösterilmiştir.

Aylık biniş sayısına göre belirlenen hatlar sırasıyla: 63 nolu Evka 3 metro – Konak, 802 nolu Egekent aktarma – Konak, 171 nolu Tınaztepe – Konak, 554 nolu Narlıdere – Konak, 169 nolu Balçova – Konak, 23 nolu Uzundere – Konak, 285 nolu Evka 1 – Konak, 193 nolu Yurtoğlu – Konak, 181 nolu Yeşilyurt – Konak, 465 nolu Tınaztepe – Konak hatlarıdır. Algoritma incelenen her gün için sonuç üretmektedir ancak bu verilerin tamamının özetlenmesi güç olacağından, hattaki en yoğun günün verilerine göre tablo ve şekiller sunulmuştur.


Tablo 24: Konak Hatlarında Gerçekleşen 30 Günlük Biniş Sayıları

Sıra No	Hat NO	Hattın Adı	Biniş Sayısı	Sıra No	Hat NO	Hat Adı	Biniş Sayısı
1	63	EVKA3 METRO-KONAK	583.715	28	253	HALKAPINAR METRO-KONAK	168.681
2	802	EGEKENT AKT.-KONAK	580.129	29	45	GÜLTEPE-KONAK	162.327
3	171	TINAZTEPE-KONAK	367.978	30	466	ŞİRİNYER AKT.-KONAK	131.536
4	554	NARLIDERE-KONAK	357.272	31	34	ESENTEPE-KONAK	127.907
5	169	BALÇOVA-KONAK	343.646	32	588	YENİ ÇAMLIK-KONAK	120.157
6	23	UZUNDERE-KONAK	294.385	33	35	BALLIKUYU-KONAK	118.087
7	285	EVKA-1-KONAK	278.443	34	252	HALKAPINAR METRO 2-KONAK	115.699
8	193	YURTOĞLU-KONAK	273.814	35	29	KADRIYE MAH.-KONAK	110.372
9	18	YEŞİLYURT-KONAK	252.369	36	33	KADİFEKALE-KONAK	104.483
10	465	TINAZTEPE-KONAK	249.522	37	224	CENNETÇEŞME-KONAK	97.930
11	152	GAZİEMİR-KONAK	246.986	38	887	SARNIÇ AKT.-KONAK	95.472
12	42	ÇINARTEPE-KONAK	246.755	39	30	KAYNAK-KONAK	82.824
13	550	GÜNALTAY-KONAK	234.901	40	484	YEŞİLBAĞLAR-KONAK	80.444
14	374	İZKENT-KONAK	234.579	41	10	ÜÇKUYULAR İSKELE-KONAK	74.586
15	121	BOSTANLI İSKELE-KONAK	229.109	42	21	HALİL RIFAT-KONAK	71.487
16	72	İŞÇİEVLERİ-KONAK	225.107	43	157	AKTEPE MAH.-KONAK	60.448
17	104	TINAZTEPE-KONAK	222.389	44	36	ŞİRİNYER AKT.-KONAK	50.003
18	233	ESBAŞ AKT-KONAK	219.613	45	15	İNÖNÜ MAH.-KONAK	35.936
19	302	OTOGAR-KONAK	215.861	46	39	İSMETPAŞA-KONAK	26.563
20	46	ÇOBANÇEŞME-KONAK	214.049	47	251	HALKAPINAR METRO-KONAK	23.725
21	27	ÇAMLIK-KONAK	211.370	48	21	ÇİMENTEPE SİTESİ-KONAK	16.656
22	838	ŞİRİNYER AKT.-KONAK	211.147	49	920	ÇİĞLİ MERKEZ-KONAK	4.480
23	587	LİMONTEPE-KONAK	208.751	50	930	BORNOVA-KONAK	3.704
24	44	MERSİNPINAR-KONAK	193.827	51	940	BUCA-KONAK	3.479
25	19	ŞEHİTLER-KONAK	188.707	52	950	NARLIDERE-KONAK	2.467
26	20	KOOP. EVLERİ-KONAK	181.963	53	910	GAZİEMİR-KONAK	1.520
27	105	ÇAMLIKULE-KONAK	178.071				

63 nolu Evka 3 metro – Konak hattı için algoritma çalıştırıldığında kartını kullanan 152.045 yolcunun oluşturduğu 583.715 biniş kaydının % 50,35'i için iniş durağı yolculuk zincirleme algoritmasıyla, % 48,17'si Diker'in rastgele atama tahmin yöntemi yardımıyla ve % 1,49'u son durağa atama yöntemiyle tespit edilmiştir.


63 nolu Evka 3 metro – Konak hattının en yoğun zaman dilimi 23 Ekim 2017 saat 08:00-08:59 zaman dilimidir. 63 nolu Evka 3 metro – Konak hattı için algoritma neticesinde en yoğun zaman aralığındaki gidiş yönündeki talebin biniş ve iniş duraklarına göre dağılımı Şekil 41'de; dönüş yönündeki talebin biniş ve iniş duraklarına göre dağılımı Şekil 42'de gösterilmiştir. 63 nolu Evka 3 metro – Konak hattındaki en yoğun gündeki talebin zamana göre dağılımı Şekil 43'de gösterilmiştir.

Şekil 41: 63 Nolu Evka 3 Metro – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Hattın gidiş yönündeki başlangıç duraklarında biniş sayıları zikzaklı bir grafik çizmesine rağmen son duraklardaki biniş sayılarına göre yüksek seviyede gerçekleşmiştir. En yüksek binişin “Evka 3 Aktarma Merkezi” ve “Hükümet Konağı” duraklarında gerçekleştiği gözlenmiştir. İnişler hattın başlarında düşük sayıda iken hattın son duraklarına doğru iniş-çıkışlı da olsa artan bir grafik göstermiştir. En yüksek inişin “Liman” ve “İskele” duraklarında olduğu gözlenmiştir.

Şekil 42: 63 Nolu Evka 3 Metro – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı




Hattın dönüş yönündeki başlangıç duraklarında biniş sayıları zikzaklı bir grafik çizmesine rağmen son duraklardaki biniş sayılarına göre yüksek seviyede gerçekleşmiştir. En yüksek binişin “Konak”, “Çocuk Hastanesi” ve “Hocazade Camii” duraklarında gerçekleştiği gözlenmiştir. İnişler hattın başlarında düşük sayıda iken

hattın son duraklarına doğru iniş-çıkışlı da olsa artan bir grafik göstermiştir. En yüksek inişlerin “Hükümet Konağı” ve Suphi Koyuncu” duraklarında olduğu gözlenmiştir.

Evka 3 Metro – Konak hattının en yoğun olduğu 23 Ekim 2017 Cumartesi günü sabah saatlerinde 13:00-13:59 zaman dilimine kadar gidiş yönünde daha fazla biniş görülürken, bu zaman diliminden sonra dönüş yönündeki binişlerin daha fazla olduğu Şekil 43’de görülmektedir. Her iki yönde de sabah 08:00-08:59 zaman diliminde ve akşam üzeri 15:00-15:59 zaman diliminde binişlerin tepe yaptığı görülebilir. Akşam üzeri 18:00-18:59 zaman diliminde dönüş yönü için üçüncü bir tepe noktası olduğu söylenebilir.

Şekil 43: 63 Nolu Evka 3 Metro – Konak Hattında Talebin Zamana Göre Dağılımı




802 nolu Egekent aktarma – Konak hattı için algoritma çalıştırıldığında kartını kullanan 146.553 yolcunun oluşturduğu 580.129 biniş kaydının %58,54’ü için iniş durağı yolculuk zincirleme algoritmasıyla, %33,23’ü Diker’in rastgele atama tahmin yöntemi yardımıyla ve % 8,23’ü son durağa atama yöntemiyle tespit edilmiştir.

802 Nolu Egekent aktarma – Konak hattı için algoritma neticesinde en yoğun zaman aralığındaki gidiş yönündeki talebin biniş ve iniş duraklarına göre dağılımı Şekil 44’de, dönüş yönündeki talebin biniş ve iniş duraklarına göre dağılımı Şekil 45’te gösterilmiştir.


802 Nolu Egekent aktarma – Konak hattındaki en yoğun gündeki talebin zamana göre dağılımı Şekil 46’da gösterilmiştir.

Şekil 44: 802 Nolu Egekent Aktarma – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Hattın gidiş yönündeki başlangıç duraklarında biniş sayıları zikzaklı bir grafik çizmesine rağmen son duraklardaki biniş sayılarına göre yüksek seviyede gerçekleşmiştir. En yüksek talebin “Turan” ve “Bayraklı Üst Geçit” duraklarında gerçekleştiği gözlenmiştir. İnişler hattın başlarında düşük sayıda iken hattın son duraklarına doğru iniş-çıkışlı da olsa artan bir grafik göstermiştir. En yüksek inişlerin “Liman” ve “İskele” duraklarında gerçekleştiği gözlenmiştir.

Şekil 45: 802 Nolu Egekent Aktarma – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı




Hattın “Serinkuyu” durağına kadar olan kısmında biniş sayıları zikzaklı bir grafik çizmesine rağmen son duraklardaki biniş sayılarına göre yüksek seviyede gerçekleşmiştir. En yüksek talebin “Konak” ve “Sosyal Sigortalar Kurumu”

duraklarında gerçekleştiği gözlenmiştir. İnişler hattın başlarında düşük sayıda iken hattın son duraklarına doğru iniş-çıkışlı da olsa artan bir grafik göstermiştir. En yüksek inişler “Eğitim Gönüllüleri” ve “Karşıyaka Egekent Aktarma Merkezi” duraklarında gerçekleştiği görülmüştür.

Egekent Aktarma – Konak hattının en yoğun olduğu 31 Ekim 2017 Pazar günü sabah saatlerinde 13:00-13:59 zaman dilimine kadar gidiş yönünde daha fazla biniş görülürken, bu zaman diliminden sonra dönüş yönündeki binişlerin daha fazla olduğu Şekil 46’da görülmektedir. Gidiş yönünde sabah 07:00-07:59 zaman diliminde ve akşam üzeri 15:00-15:59 zaman diliminde binişlerin tepe yaptığı görülebilir. Dönüş yönünde ise sabah 08:00-08:59 zaman diliminde akşam üzeri ise 17:00-17:59 zaman diliminde tepe yaptığı görülebilir.

Şekil 46: 802 Nolu Egekent Aktarma – Konak Hattında Talebin Zamana Göre Dağılımı




171 nolu Tınaztepe – Konak hattı için algoritma çalıştırıldığında bu hatta kartını kullanan 77.674 yolcunun oluşturduğu 367.978 biniş kaydının % 31,44’ü için iniş durağı aktarmalar yardımıyla, % 35,72’si sabah ve akşam son binişlerden, % 31,47’si Diker’in rastgele atama tahmin yöntemi yardımıyla ve % 1,37’si son durağa atama yöntemiyle tespit edilmiştir.

171 nolu Tınaztepe – Konak hattı için algoritma neticesinde en yoğun zaman aralığındaki gidiş yönündeki talebin biniş ve iniş duraklarına göre dağılımı Şekil 47’de, dönüş yönündeki talebin biniş ve iniş duraklarına göre dağılımı Şekil 48’de gösterilmiştir.


171 nolu Tınaztepe – Konak hattındaki en yoğun gündeki talebin zamana göre dağılımı Şekil 49’da gösterilmiştir.

Şekil 47: 171 Nolu Tınaztepe – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Hattın “Şeboy” durağına kadar olan kısmında biniş sayıları zikzaklı bir grafik çizerken son duraklardaki biniş sayılarına göre yüksek seviyede gerçekleşmiştir. En yüksek binişin “Tınaztepe” ve “Buca Kooperatif Son Durak” duraklarında gerçekleştiği gözlenmiştir. İnişler hattın başlarında düşük sayıda iken hattın son duraklarına doğru iniş-çıkışlı da olsa artan bir grafik göstermiştir. İnişin en yoğun olduğu duraklar “Akıncılar Merkez” ve “Konak” duraklarıdır.


Şekil 48: 171 Nolu Tınaztepe – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Hattın “Köşe” durağına kadar olan kısmında biniş sayıları zikzaklı bir grafik çizerken son duraklardaki biniş sayılarına göre yüksek seviyede gerçekleşmiştir. En yüksek binişin “Konak” ve “Akıncılar Merkez” duraklarında gerçekleştiği

gözlenmiştir. İnişler hattın başlarında zik zaklı ve düşük seviyede iken hattın son duraklarına doğru iniş-çıkışlı da olsa artan bir grafik göstermiştir. İnişin en yoğun olduğu duraklar “Yasemin”, “Buca Kooperatif Meydan” ve “Tınaztepe” duraklarıdır.

Şekil 49: 171 Nolu Tınaztepe – Konak Hattında Talebin Zamana Göre Dağılımı




Tınaztepe – Konak hattının en yoğun olduğu 23 Ekim 2017 Cumartesi günü sabah saatlerinde 14:00-14:59 zaman dilimine kadar gidiş yönünde daha fazla biniş görülürken, bu zaman diliminden sonra dönüş yönündeki binişlerin daha fazla olduğu Şekil 49’da görülmektedir. Gidiş yönünde sabah 07:00-07:59 zaman diliminde ve akşam üzeri 16:00-16:59 zaman diliminde binişlerin tepe yaptığı görülebilir. Dönüş yönünde ise sabah 08:00-08:59 zaman diliminde akşam üzeri ise 17:00-17:59 zaman diliminde tepe yaptığı görülebilir.

554 nolu Narlıdere – Konak hattı için algoritma çalıştırıldığında bu hatta kartını kullanan 144.777 yolcunun oluşturduğu 357.272 biniş kaydının % 38,51’i için iniş durağı aktarmalar yardımıyla, % 18,96’sı sabah ve akşam son binişlerden, % 39,16’sı Diker’in rastgele atama tahmin yöntemi yardımıyla ve % 3,38’i son durağa atama yöntemiyle tespit edilmiştir.

554 nolu Narlıdere – Konak hattı için algoritma neticesinde en yoğun zaman aralığındaki gidiş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 50’de, dönüş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 51’de gösterilmiştir.


554 nolu Narlıdere – Konak hattındaki en yoğun gündeki talebin zamana göre dağılımı Şekil 52’de gösterilmiştir.

Şekil 50: 554 Nolu Narlıdere – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı




Hat genelinde biniş sayıları zikzaklı bir grafik çizmiştir. En yüksek binişin “Narlıdere” ve “Dokuz Eylül” duraklarında gerçekleştiği gözlenmiştir. Binişlerin hattın son duraklarında düşük olması beklenirken “Mektupçu” durağında yoğun bir biniş gözlenmiştir. Bu bölgede çok sayıda okul olduğu ve binişlerin bu nedenle yoğun olabileceği düşünülmüştür. İnişler hattın başlarında düşük sayıda iken hattın son duraklarına doğru iniş-çıkışlı da olsa artan bir grafik göstermiştir. İnişin en yoğun olduğu duraklar “Üçkuyular Meydan” ve “Konak” duraklarıdır.

Şekil 51: 554 Nolu Narlıdere – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Hattın “Kantar” durağına kadar olan kısmında biniş sayıları zikzaklı bir grafik çizerken son duraklardaki biniş sayılarına göre yüksek seviyede gerçekleşmiştir. En yüksek binişin “Karataş” ve “Üçkuyular Pazaryeri” duraklarında gerçekleştiği gözlenmiştir. İnişler hattın başlarında düşük sayıda iken hattın ortalarında iniş-çıkışlı da olsa artan bir grafik göstermiştir. İnişin en yoğun olduğu duraklar “Üçkuyular Pazaryeri”, ve “Balcı” duraklarıdır.

Şekil 52: 554 Nolu Narlıdere – Konak Hattında Talebin Zamana Göre Dağılımı




Narlıdere – Konak hattının en yoğun olduğu 31 Ekim 2017 Pazar günü gidiş yönünde sabah 07:00-07:59 zaman diliminde ve akşam üzeri 16:00-16:59 zaman diliminde binişlerin tepe yaptığı Şekil 52’de görülebilir. Dönüş yönünde ise binişlerin zikzaklı bir grafik çizdiği görülmektedir. Dönüş yönünde sabah 08:00-08:59 zaman diliminde akşam üzeri ise 17:00-17:59 zaman diliminde tepe yaptığı görülebilir.

169 nolu Balçova – Konak hattı için algoritma çalıştırıldığında bu hatta kartını kullanan 118.535 yolcunun oluşturduğu 343.646 biniş kaydının % 36,4’ü için iniş durağı aktarmalar yardımıyla, % 8,3’ü sabah ve akşam son binişlerden, % 51,15’i Diker’in rastgele atama tahmin yöntemi yardımıyla ve % 4,16’sı son durağa atama yöntemiyle tespit edilmiştir.

169 nolu Balçova – Konak hattı için algoritma neticesinde en yoğun zaman aralığındaki gidiş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 53’de, dönüş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 54’de gösterilmiştir.


169 nolu Balçova – Konak hattındaki en yoğun gündeki talebin zamana göre dağılımı Şekil 55’de gösterilmiştir.

Şekil 53: 169 Nolu Balçova – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı




Şekil 53’de duraklardaki binişlerin inişli-çıkışlı bir grafik çizdiği görülmektedir. En yoğun binişler “Üçkuyular Meydan” ve “Gümüş” duraklarında gerçekleşmiştir. İnişlerin başlangıçta düşük seviyelerde iken “Üçkuyular Meydan” durağında önemli bir tepe yaptığı görülmektedir. En yoğun inişlerin “Üçkuyular Meydan” ve “Konak” duraklarında gerçekleştiği görülmüştür.

Şekil 54: 169 Nolu Balçova – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Şekil 54’de binişlerin zikzaklı bir trend izlediği görülmektedir. En yoğun binişler “Üçkuyular Pazaryeri” ve “Balçova Kahveler” duraklarında gerçekleşmiştir. İnişlerde zikzaklı bir trend göstermektedir. İnişlerin en yoğun olduğu duraklar “İkiztepe” ve “Aydıbi” duraklarıdır.

Şekil 55: 169 Nolu Balçova – Konak Hattında Talebin Zamana Göre Dağılımı




Balçova – Konak hattının en yoğun olduğu 10 Ekim 2017 Pazar günü gidiş yönünde sabah 07:00-07:59 zaman diliminde ve akşam üzeri 17:00-17:59 zaman diliminde binişlerin tepe yaptığı Şekil 55’de görülebilir. Dönüş yönünde sabah 08:00-08:59 zaman diliminde akşam üzeri ise 17:00-17:59 zaman diliminde tepe yaptığı görülebilir.

23 nolu Uzundere – Konak hattı için algoritma çalıştırıldığında bu hatta kartını kullanan 77.902 yolcunun oluşturduğu 294.385 biniş kaydının % 30,81’i için iniş durağı aktarmalar yardımıyla, % 26,65’i sabah ve akşam son binişlerden, % 40,44’ü Diker’in rastgele atama tahmin yöntemi yardımıyla ve % 2,1’i son durağa atama yöntemiyle tespit edilmiştir.

23 nolu Uzundere – Konak hattı için algoritma neticesinde en yoğun zaman aralığındaki gidiş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 56’da, dönüş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 57’de gösterilmiştir.


23 nolu Uzundere – Konak hattındaki en yoğun gündeki talebin zamana göre dağılımı Şekil 58’de gösterilmiştir.

Şekil 56: 23 Nolu Uzundere – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Şekil 56’da binişlerin zikzaklı da olsa ilk duraklarda yüksek düzeyde olduğu ve “Eski İzmir Karakolu” durağından sonra azalan bir trend izlediği görülmektedir. Binişlerin en yüksek olduğu duraklar “Gürsel” ve “Eski İzmir Karakolu” duraklarıdır. İniş ilk duraklarda hiç yok veya çok azken özellikle “Eski İzmir Karakolu” durağından sonra zikzaklı da olsa artan bir trend izlemiştir. İnişlerin en yoğun olduğu duraklar “Kız Yurdu” ve “Etnoğrafya Müzesi” duraklarıdır.


Şekil 57: 23 Nolu Uzundere – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Binişler hattın dönüş yönündeki ilk duraklarında daha yoğun iken son duraklarında azaldığı Şekil 57’de görülmektedir. En yoğun binişler “Mezarlık Başı” ve “Eşrefpaşa” duraklarında gerçekleşmiştir. İlk duraklarda inişler düşük düzeyde iken

hattın orta duraklarında yoğunlaşma gözlenmiştir. Hattın son duraklarındaki inişler başlardaki duraklara göre daha yoğundur. En yoğun inişler “Bayram Kahya”, ve “Yıkık Cami” duraklarında gerçekleşmiştir.

Şekil 58: 23 Nolu Uzundere – Konak Hattında Talebin Zamana Göre Dağılımı




Uzundere – Konak hattının en yoğun olduğu 4 Ekim 2017 Pazartesi günü sabah saatlerinde 14:00-14:59 zaman dilimine kadar gidiş yönünde daha fazla biniş görülürken, bu zaman diliminden sonra dönüş yönündeki binişlerin daha fazla olduğu Şekil 58’de görülmektedir. Gidiş yönünde sabah 07:00-07:59 zaman diliminde ve öğleden sonra 14:00-14:59 zaman diliminde binişlerin tepe yaptığı görülebilir. Dönüş yönünde ise sabah 09:00-09:59 zaman diliminde akşam üzeri ise 17:00-17:59 zaman diliminde tepe yaptığı görülebilir.

285 nolu Evka 1 – Konak hattı için algoritma çalıştırıldığında bu hatta kartını kullanan 81.463 yolcunun oluşturduğu 278.443 biniş kaydının % 28,88’i için iniş durağı aktarmalar yardımıyla, % 17,62’si sabah ve akşam son binişlerden, % 42,72’si Diker’in rastgele atama tahmin yöntemi yardımıyla ve % 10,78’i son durağa atama yöntemiyle tespit edilmiştir.

285 nolu Evka 1 – Konak hattı için algoritma neticesinde en yoğun zaman aralığındaki gidiş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 59’da, dönüş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 60’da gösterilmiştir.


285 nolu Evka 1 – Konak hattındaki en yoğun gündeki talebin zamana göre dağılımı Şekil 61’de gösterilmiştir.

Şekil 59: 285 Nolu Evka 1 – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Binişler hattın gidiş yönündeki ortalarındaki duraklarında daha yoğun iken hattın ilk duraklarında ve son duraklarında daha az olduğu Şekil 59’da görülmektedir. En yoğun binişler “Betontaş” ve “Mehmetçik” duraklarında gerçekleşmiştir. İlk duraklarda inişler düşük düzeyde iken hattın orta duraklarında yoğunlaşma gözlenmiştir. Hattın son duraklarındaki inişler başlardaki duraklara göre daha yoğundur. En yoğun inişler “Şirinyer Karakol” ve “Konak” duraklarında gerçekleşmiştir.


Şekil 60: 285 Nolu Evka 1 – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Binişler hattın dönüş yönündeki ilk duraklarında daha yoğun iken hattın son duraklarında daha az olduğu Şekil 60’da görülmektedir. En yoğun binişler “Kavafılar” ve “Şirinyer Pazar Yeri” duraklarında gerçekleşmiştir. İlk duraklarda inişler düşük

düzeyde iken hattın orta duraklarında yoğunlaşma gözlenmiştir. Hattın son duraklarındaki inişler başlardaki duraklara göre daha yoğundur. En yoğun inişler “Nato” ve “Evka 1” duraklarında gerçekleşmiştir.

Şekil 61: 285 Nolu Evka 1 – Konak Hattında Talebin Zamana Göre Dağılımı




Evka 1 – Konak hattının en yoğun olduğu 18 Ekim 2017 Pazartesi günü gidiş yönünde sabah 07:00-07:59 zaman diliminde ve akşam üzeri 16:00-16:59 zaman diliminde binişlerin tepe yaptığı Şekil 61’de görülebilir. Dönüş yönünde ise sabah 08:00-08:59 zaman diliminde akşam üzeri ise 18:00-18:59 zaman diliminde tepe yaptığı görülebilir.

193 nolu Yurtoğlu – Konak hattı için algoritma çalıştırıldığında bu hatta kartını kullanan 75.102 yolcunun oluşturduğu 273.814 biniş kaydının % 30,07’si için iniş durağı aktarmalar yardımıyla, % 34,91’i sabah ve akşam son binişlerden, % 28,42’si Diker’in rastgele atama tahmin yöntemi yardımıyla ve % 6,6’sı son durağa atama yöntemiyle tespit edilmiştir.

193 nolu Yurtoğlu – Konak hattı için algoritma neticesinde en yoğun zaman aralığındaki gidiş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 62’de, dönüş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 63’de gösterilmiştir.


193 nolu Yurtoğlu – Konak hattındaki en yoğun gündeki talebin zamana göre dağılımı Şekil 64’de gösterilmiştir.

Şekil 62: 193 Nolu Yurtoğlu – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Binişler hattın gidiş yönündeki ilk duraklarında daha yoğun iken hattın son duraklarında daha az olduğu Şekil 62’de görülmektedir. En yoğun binişler “Yurtoğlu Son Durak” ve “Narlık” duraklarında gerçekleşmiştir. İlk duraklarda inişler düşük düzeyde iken hattın orta duraklarında yoğunlaşma gözlenmiştir. Hattın son duraklarındaki inişler başlardaki duraklara göre daha yoğundur. En yoğun inişler “Kız Yurdu” ve “Bahribaba” duraklarında gerçekleşmiştir.


Şekil 63: 193 Nolu Yurtoğlu – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Binişler hattın dönüş yönündeki ilk duraklarında daha yoğun iken hattın son duraklarında daha az olduğu Şekil 63’de görülmektedir. En yoğun binişler “Bahribaba” ve “Eşrefpaşa” duraklarında gerçekleşmiştir. İlk duraklarda inişler düşük düzeyde iken hattın orta duraklarında yoğunlaşma gözlenmiştir. Hattın son

duraklarında yoğun inişler gözlenmiştir. En yoğun inişler “Bayram Kahya” ve “Yurtoğlu Son Durak” duraklarında gerçekleşmiştir.

Şekil 64: 193 Nolu Yurtoğlu – Konak Hattında Talebin Zamana Göre Dağılımı




Yurtoğlu – Konak hattının en yoğun olduğu 2 Ekim 2017 Cumartesi günü sabah saatlerinde 15:00-15:59 zaman dilimine kadar gidiş yönünde daha fazla biniş görülürken, bu zaman diliminden sonra dönüş yönündeki binişlerin daha fazla olduğu Şekil 64’de görülmektedir. Gidiş yönünde sabah 07:00-07:59 zaman diliminde ve öğleden sonra 15:00-15:59 zaman diliminde binişlerin tepe yaptığı görülebilir. Dönüş yönünde ise sabah 08:00-08:59 zaman diliminde akşam üzeri ise 18:00-18:59 zaman diliminde tepe yaptığı görülebilir.

18 nolu Yeşilyurt – Konak hattı için algoritma çalıştırıldığında bu hatta kartını kullanan 76.142 yolcunun oluşturduğu 252.369 biniş kaydının % 31,0’i için iniş durağı aktarmalar yardımıyla, % 20,3’ü sabah ve akşam son binişlerden, % 47,13’ü Diker’in rastgele atama tahmin yöntemi yardımıyla ve % 1,56’sı son durağa atama yöntemiyle tespit edilmiştir.

18 nolu Yeşilyurt – Konak hattı için algoritma neticesinde en yoğun zaman aralığındaki gidiş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 65’de, dönüş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 66’da gösterilmiştir.


18 nolu Yeşilyurt – Konak hattındaki en yoğun gündeki talebin zamana göre dağılımı Şekil 67’de gösterilmiştir.

Şekil 65: 18 Nolu Yeşilyurt – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Binişler hattın gidiş yönündeki ortalarda bulunan duraklarda daha yoğun iken hattın son duraklarında daha az olduğu Şekil 65’de görülmektedir. En yoğun binişler “Yeşilyurt Merkez Cami” ve “Üzümcü İlk Öğretim Okulu” duraklarında gerçekleşmiştir. İlk duraklarda inişler düşük düzeyde iken hattın son duraklarında yoğunlaşma gözlenmiştir. En yoğun inişler “Yeşilyurt İtfaiye” ve “Etnoğrafya Müzesi” duraklarında gerçekleşmiştir.


Şekil 66: 18 Nolu Yeşilyurt – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Binişler hattın dönüş yönündeki ilk duraklarında daha yoğun iken hattın son duraklarında daha az olduğu Şekil 66’da görülmektedir. En yoğun binişler “Etnoğrafya Müzesi” ve “Üçyol Metro” duraklarında gerçekleşmiştir. İlk duraklarda inişler düşük düzeyde iken hattın orta duraklarında yoğunlaşma gözlenmiştir. Hattın son

duraklarındaki inişler başlardaki duraklara göre daha yoğundur. En yoğun inişler “Cumhuriyet Ticaret Meslek Lisesi” ve “Öztepe” duraklarında gerçekleşmiştir.

Şekil 67: 18 Nolu Yeşilyurt – Konak Hattında Talebin Zamana Göre Dağılımı




Yeşilyurt – Konak hattının en yoğun olduğu 26 Ekim 2017 Salı günü sabah saatlerinde 14:00-14:59 zaman dilimine kadar gidiş yönünde daha fazla biniş görülürken, bu zaman diliminden sonra dönüş yönündeki binişlerin daha fazla olduğu Şekil 67’de görülmektedir. Gidiş yönünde sabah 07:00-07:59 zaman diliminde ve öğleden sonra 14:00-14:59 zaman diliminde binişlerin tepe yaptığı görülebilir. Dönüş yönünde ise sabah 08:00-08:59 zaman diliminde akşam üzeri ise 17:00-17:59 zaman diliminde tepe yaptığı görülebilir.

465 nolu Tınaztepe – Konak hattı için algoritma çalıştırıldığında bu hatta kartını kullanan 76.821 yolcunun oluşturduğu 249.522 biniş kaydının % 31,5’u için iniş durağı aktarmalar yardımıyla, % 15,35’i sabah ve akşam son binişlerden, % 49,42’si Diker’in rastgele atama tahmin yöntemi yardımıyla ve % 3,72’si son durağa atama yöntemiyle tespit edilmiştir.

465 nolu Tınaztepe – Konak hattı için algoritma neticesinde en yoğun zaman aralığındaki gidiş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 68’de, dönüş yönünde talebin biniş ve iniş duraklarına göre dağılımı Şekil 69’da gösterilmiştir.


465 nolu Tınaztepe – Konak hattındaki en yoğun günde talebin zamana göre dağılımı Şekil 70’de gösterilmiştir.

Şekil 68: 465 Nolu Tınaztepe – Konak Hattında Gidiş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Binişler hattın gidiş yönündeki ilk duraklarında daha yoğun iken hattın son duraklarında daha az olduğu Şekil 68’de görülmektedir. En yoğun binişler “Yeşilkent” ve “Buca Doğum Evi” duraklarında gerçekleşmiştir. İlk duraklarda inişler düşük düzeyde iken hattın orta duraklarında yoğunlaşma gözlenmiştir. Hattın son duraklarındaki inişler başlardaki duraklara göre daha yoğundur. En yoğun inişler “Şirinyer Karakol” ve “Konak” duraklarında gerçekleşmiştir.


Şekil 69: 465 Nolu Tınaztepe – Konak Hattında Dönüş Yönündeki Talebin Biniş ve İniş Duraklarına Göre Dağılımı



Binişler hattın dönüş yönündeki ilk duraklarında daha yoğun iken hattın son duraklarında daha az olduğu Şekil 69’da görülmektedir. En yoğun binişler “Konak” ve “Kavafar” duraklarında gerçekleşmiştir. İlk duraklarda inişler düşük düzeyde iken

hattın orta duraklarında yoğunlaşma gözlenmiştir. Hattın son duraklarındaki inişler başlardaki duraklara göre daha yoğundur. En yoğun inişler “Nato” ve “Buca Sağlık Ocağı” duraklarında gerçekleşmiştir.

Şekil 70: 465 Nolu Tınaztepe – Konak Hattında Talebin Zamana Göre Dağılımı



Tınaztepe – Konak hattının en yoğun olduğu 26 Ekim 2017 Salı günü sabah saatlerinde 15:00-15:59 zaman dilimine kadar gidiş yönünde daha fazla biniş görülürken, bu zaman diliminden sonra dönüş yönündeki binişlerin daha fazla olduğu Şekil 70’de görülmektedir. Gidiş yönünde sabah 07:00-07:59 zaman diliminde ve akşam üzeri 17:00-17:59 zaman diliminde binişlerin tepe yaptığı görülebilir. Dönüş yönünde ise sabah 08:00-08:59 zaman diliminde akşam üzeri ise 17:00-17:59 zaman diliminde tepe yaptığı görülebilir.

4.12.2. Durak Seviyesinde BV Matris Tahmini

Biniş ve iniş durakları tespit edilen kayıtlara göre veri setindeki her biniş kaydı için başlangıç ve varış duraklarının BV matriste karşılığı olan satır ve sütunların kesiştiği hücrenin değeri bir arttırılır. Bütün veri setinde ilgili günün her zaman dilimi için hattın gidiş yönünde ayrı ve dönüş yönünde ayrı bir BV matrisi bu şekilde hesaplanır.

BV Matrisi hesaplandıktan sonra hattın yük profilleri, maksimum talep düzeyi vb. istatistikleri hesaplamak mümkündür. Her hat için önce gidiş yönündeki BV matristen bu yöndeki maksimum talep düzeyi hesaplanır. Daha sonra dönüş yönündeki BV matris yardımıyla bu yöndeki maksimum talep hesaplanır. Hesaplama için kullanılan kodlar EK 4’de verilmiştir.

4.12.3. Hesaplanan Talep Verilerine Göre Talep Tahmini

Prototip uygulama geliştirilirken yazılan YSA kodları kullanılarak hafta içi verileri için bir model oluşturulmuş parametre optimizasyonu yapılarak tahmine hazır hale getirilmiştir. Aynı kodlar yardımıyla hafta sonu günleri için başka bir YSA modeli oluşturulmuş ve hafta sonu talep verileriyle eğitilmiştir. Bu model için de parametre optimizasyonu yapılmış ve tahmine hazır hale getirilmiştir.

Belirlenen bir tarihin istenilen bir zaman dilimi için gidiş veya dönüş talebini tahmin etmek üzere yukarıda anlatılan yöntemle iki YSA kümesi oluşturulmuştur. Yani gidiş yönü için hafta içi ve hafta sonu tahminleyici ve dönüş yönü için hafta içi ve hafta sonu tahminleyici olmak üzere toplam dört adet YSA modeli oluşturulmuş ve ilgili verilerle eğitilip parametre optimizasyonu ile tahmine hazır hale getirilmiştir. Günün her zaman dilimi için tahmin yapmak üzere bir YSA oluşturulacak olursa günde 20 zaman dilimi için talep verisi bulunduğundan $4 \times 20 = 80$ adet YSA modeli oluşturmak gereklidir. Zaman kısıtı nedeniyle sadece her hattın en yoğun olduğu günün en yoğun zaman dilimi için tahmin edici YSA modeli oluşturulmuştur.

Yapılan incelemede hafta içi günlerdeki talep yapısı ile hafta sonu talep yapısının farklı olduğu gözlenmiştir. Bu nedenle herhangi bir zaman dilimi için gelecek öngörüsünde bulunacak yapay sinir ağının eğitiminde doğru verilerin kullanılması önem taşıyacaktır. Hafta içi günlere ilişkin tahminleyici YSA hafta içi talep verileriyle, hafta sonu günlere ilişkin tahminleyici YSA hafta sonu talep verileriyle eğitilmelidir. Hafta içi verileriyle eğitilen YSA'nın performans değerleri Tablo 25'de, hafta sonu verileriyle eğitilen YSA'nın performans değerleri Tablo 26'da gösterilmiştir.

Tablo 25'de görüldüğü gibi YSA'nın ürettiği tahminler diğer yöntemlere göre gerçek verilere çok daha yakındır. Bu nedenle hafta içi verileriyle eğitilen bu YSA gelecek öngörüsü için güvenle kullanılabilir.

Tablo 25: Hafta İçi için Tahmin Yöntemlerinin Farklı Servis Zamanları için Karşılaştırılması

07:00-07:59					08:00-08:59				
Yöntem	MAE	MSE	RMSE	MAPE (%)	Yöntem	MAE	MSE	RMSE	MAPE (%)
YSA	0,625	0,875	0,935	0,2	YSA	0,250	0,250	0,500	0,092
Hareketli Ortalamalar	20,938	492,969	22,203	6,9	Hareketli Ortalamalar	13,188	276,281	16,6217	4,544
Ağırlıklı H. Ortalamalar	18,388	489,059	22,115	6,0	Ağırlıklı H. Ortalamalar	16,938	426,251	20,6459	5,883
Üstel Düzeltme	16,549	451,175	21,241	5,5	Üstel Düzeltme	18,152	448,475	21,177	6,328
Regresyon Analizi	18,308	480,490	21,920	6,0	Regresyon Analizi	9,7042	131,533	11,469	3,407

Tablo 26’da hafta sonu verileriyle eğitilen YSA’nın diğer yöntemlerden daha az hatayla tahmin üretebildiği görülmektedir. Bu nedenle hafta sonu talebini tahmin etmek için hafta sonu verileriyle eğitilmiş YSA güvenle kullanılabilir.

Tablo 26: Hafta Sonu için Tahmin Yöntemlerinin Farklı Servis Zamanları için Karşılaştırılması

12:00-12:59					13:00-13:59				
Yöntem	MAE	MSE	RMSE	MAPE	Yöntem	MAE	MSE	RMSE	MAPE
YSA	1,063	5,813	2,411	1,770	YSA	1,000	5,625	2,372	1,539
Hareketli Ortalamalar	4,938	139,156	11,796	8,566	Hareketli Ortalamalar	3,875	83,031	9,112	5,794
Ağırlıklı H. Ortalamalar	5,475	186,005	13,638	9,590	Ağırlıklı H. Ortalamalar	4,250	98,485	9,924	6,335
Üstel Düzeltme	6,187	222,930	14,931	10,856	Üstel Düzeltme	4,236	107,397	10,363	6,299
Regresyon Analizi	3,103	53,079	7,286	5,139	Regresyon Analizi	2,274	29,738	5,453	3,509

Bir tarih ve bir zaman dilimi verildiğinde (örneğin 02/11/2017 saat 08:00-08:59 gibi) o tarihe ulaşınca kadar tahmin süreci devam eder. Örneğin 01/11/2017 pazartesi günü olduğundan son iki hafta içi günü olan 28/10/2017 ve 29/10/2017’nin 08:00-08:59 zaman dilimi verileri kullanılarak 01/11/2017 için talep tahmin edilir. Daha sonra 29/10/2017 talep verisi ve 01/11/2017 için talep tahmini girdi olarak kullanılarak 02/11/2017 için talep tahmini yapılır.

4.12.4. Tahmini Talep ve Hat Parametreleri Kullanılarak Optimum Sefer Sıklıklarının Önerilen Algoritma ile Belirlenmesi

Prototip uygulamada geliştirilen optimum sefer sıklığı optimizasyon modelleri kullanılarak elde edilen çizelgeler hatların mevcut çizelgeleriyle karşılaştırılmıştır.

63 nolu Evka 3 Metro – Konak hattı için hafta sonu gidiş yönünde en yoğun zaman dilimi olan 08:00-08:59 zaman aralığı için tahmin edilen ortalama hat talebi

hafta içi 1.110 yolcudur. Maliyetler hesaba katılırken 13,3 km mesafedeki yakıt tüketimi hesaplanıp mazot fiyatıyla çarpılmış (6 ₺) bir seferin maliyeti 42,29 ₺ olarak hesaplanmıştır. Hatta 19 körüklü, 1 solo otobüs hizmet vermektedir. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 27’de gösterilmiştir.

Tablo 27: 63 Nolu Evka 3 Metro – Konak Hattının Hafta Sonu Gidiş Yönü İçin Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	9	8	14	18	15	11	11
Sefer Başına Yolcu Sayısı	123	139	79	62	74	101	101
Durakta Bekleme Süresi	6,67	7,50	4,29	3,33	4,00	5,45	5,45
Maliyet	381	338	592	761	634	465	465
m ² 'ye Düşen Yolcu Sayısı	3,18	3,60	2,16	1,62	1,99	2,74	2,74
Atıl Kapasite	218	70	955	1545	1103	513	513
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl Zaman Körüklü	10,45	11,40	5,7	1,9	4,8	8,6	8,6
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,55	0,60	0,3	0,1	0,3	0,5	0,5
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		98,4	3.724,6	5.153,0	7.220,7	5.294,2	5.294,2

ESHOT’un çizelgelerinde 63 Nolu “Evka 3 Metro – Konak” hattı için sefer sıklığının 9 olduğu görülmüştür. Tablo 27’deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 8’dir. ESHOT’un mevcut çizelgesinde sefer sıklığını 9 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6’da 14 ve Model 9’da 18 olarak hesaplanmıştır. Model 6’da bekleme süresinin, Model 9’da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9’dan daha dengeli bir sefer sıklığı olan 15 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, maliyeti ve m²'ye düşen yolcu sayısını minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 6 ile model 9 arasında yer aldığı görülmektedir. Model 13’te pozitif ve negatif sapmaları, durakta bekleme süresini ve maliyeti dikkate almaktadır. Bu modelde hesaplanan optimum sefer sıklığı 11 olarak belirlenmiştir. Bu model, model 12’ye göre daha düşük maliyete neden olurken, durakta bekleme süresinin ve m²'ye düşen yolcu sayısının artmasına neden

olmaktadır. Model 13’de m^2 ’ye düşen yolcu sayısının 2,86’dan küçük olması nedeniyle optimum sefer sıklığı model 14’de de 11 olarak hesaplanmıştır. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Bu nedenle hesaplanan sefer sıklığı (11) ESHOT’un belirlediği sefer sıklığından (9) bir miktar fazla olmuştur. Bu sefer sıklığı uygulanacak olursa maliyet ve atıl kapasite daha yüksek olacaktır ama yolcular daha konforlu ulaşım imkanına kavuşacaklardır. Bu durum yolcu memnuniyetini arttıracaktır.

63 nolu Evka 3 Metro – Konak hattı için hafta sonu dönüş yönünde 18:00-18:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 1.063 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 28’de gösterilmiştir.

Tablo 28: 63 Nolu Evka 3 Metro – Konak Hattının Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	10	8	14	18	14	11	11
Sefer Başına Yolcu Sayısı	106	133	76	59	76	97	97
Durakta Bekleme Süresi	6,00	7,50	4,29	3,33	4,29	5,45	5,45
Maliyet	423	338	592	761	592	465	465
m^2 ’ye Düşen Yolcu Sayısı	2,74	3,44	2,04	1,57	2,04	2,64	2,64
Atıl Kapasite	412	117	1002	1592	1002	560	560
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	9,50	11,40	5,7	1,9	5,7	8,6	8,6
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,50	0,60	0,3	0,1	0,3	0,5	0,5
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		154,8	3.781,0	5.168,0	7.187,2	5.350,6	5.350,6

Tablo 28’deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 8’dir. ESHOT’un mevcut çizelgesinde sefer sıklığını 10 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6’da 14 ve Model 9’da 18 olarak hesaplanmıştır. Model 6’da bekleme süreleri Model 9’da hem bekleme süresinin hem de m^2 ’ye düşen yolcu sayısı değişkenleri dikkate alındığı için bekleme süresi ve m^2 ’ye düşen yolcu sayısı daha az olurken, maliyet artmaktadır. Model 3’e göre atıl kapasite daha fazla iken, atıl zaman daha düşük olarak gerçekleşmektedir. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 9’dan daha düşük bir sefer sıklığı olan 14 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini,

maliyeti ve m^2 'ye düşen yolcu sayısını minimize etmeye çalışmaktadır. Model 13'de optimum sefer sıklığı 11 olarak hesaplanmıştır. Model 13'te m^2 'ye düşen yolcu sayısı 2,86'dan düşük olduğundan model 14'te de aynı sonuç elde edilmiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Bu nedenle hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (10) bir miktar fazla olmuştur. Bu sefer sıklığı uygulanacak olursa maliyet ve atıl kapasite daha yüksek olacaktır ama yolcular daha konforlu ulaşım imkanına kavuşacaklardır. Bu durum yolcu memnuniyetini arttıracaktır.

63 nolu Evka 3 Metro – Konak hattı için hafta içi gidiş yönünde en yoğun zaman dilimi olan 08:00-08:59 zaman aralığı için tahmin edilen ortalama hat talebi hafta içi 911 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 29'da gösterilmiştir.

Tablo 29: 63 Nolu Evka 3 Metro – Konak hattının Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	9	7	14	17	13	11	11
Sefer Başına Yolcu Sayısı	101	130	65	54	70	83	83
Durakta Bekleme Süresi	6,67	8,57	4,29	3,53	4,62	5,45	5,45
Maliyet	381	296	592	719	550	465	465
m^2 'ye Düşen Yolcu Sayısı	2,61	3,36	1,75	1,41	1,88	2,26	2,26
Atıl Kapasite	417	122	1154	1597	1007	712	712
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	10,45	12,35	5,7	2,9	6,7	8,6	8,6
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,55	0,65	0,3	0,2	0,4	0,5	0,5
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		161,4	3.963,4	5.168,1	7.140,6	5.533,0	5.533,0

Tablo 29'daki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 7'dir. ESHOT'un mevcut çizelgesinde sefer sıklığını 9 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da 14 ve Model 9'da 17 olarak hesaplanmıştır. Model 6'da bekleme süresinin Model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9'dan daha dengeli bir sefer sıklığı olan 13 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, maliyeti ve m^2 'ye düşen yolcu

sayısını minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ve model 9 arasında yer aldığı görülmektedir. Model 13'te pozitif ve negatif sapmaları, durakta bekleme süresini ve maliyeti dikkate almaktadır. Bu modelde hesaplanan optimum sefer sıklığı 11 olarak belirlenmiştir. Bu model model 12'ye göre daha düşük maliyete neden olurken, bekleme süresinin ve m²'ye düşen yolcu sayısının artmasına neden olmaktadır. Model 13'te hesaplanan m²'ye düşen yolcu sayısı 2,86'dan düşük olduğu için model 14'te de model 13 ile aynı sonuç elde edilmiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Bu nedenle hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (9) bir miktar fazla olmuştur. Bu sefer sıklığı uygulanacak olursa maliyet ve atıl kapasite daha yüksek olacaktır ama yolcular daha konforlu ulaşım imkanına kavuşacaklardır. Bu durum yolcu memnuniyetini arttıracaktır.

63 nolu Evka 3 Metro – Konak hattı için hafta içi dönüş yönünde 18:00-18:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 880 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 30'da gösterilmiştir.

Tablo 30: 63 Nolu Evka 3 Metro – Konak Hattının Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	10	6	14	19	14	11	11
Sefer Başına Yolcu Sayısı	88	147	63	46	63	80	80
Durakta Bekleme Süresi	6,00	10,00	4,29	3,16	4,29	5,45	5,45
Maliyet	423	254	592	804	592	465	465
m ² 'ye Düşen Yolcu Sayısı	2,28	3,80	1,66	1,22	1,66	2,17	2,17
Atıl Kapasite	595	5	1185	1923	1185	743	743
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	9,50	7,03	5,7	0,9	5,7	8,6	8,6
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,50	0,37	0,3	0,1	0,3	0,5	0,5
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		10,00	4.000,6	5.177,7	7.105,7	5.570,2	5.570,2

Tablo 30'daki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 6'dır. ESHOT'un mevcut çizelgesinde sefer sıklığını 10 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da 14 ve Model 9'da 19 olarak hesaplanmıştır. Model 6'da bekleme süreleri dikkate alındığı için Model 9'da

hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmaktadır. Bu modellerde bekleme süresi ve m²'ye düşen yolcu sayısı daha az olurken, maliyet artmaktadır. Model 3'e göre atıl kapasite daha fazla iken, atıl zaman daha düşük olarak gerçekleşmektedir. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 9'dan daha düşük bir sefer sıklığı olan 14 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Model 13'de optimum sefer sıklığı 11 olarak hesaplanmıştır. Hesaplanan m²'ye düşen yolcu sayısı 2,86'dan düşük olduğu için model 14'te de aynı sonuç elde edilmiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Bu nedenle hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (10) bir miktar fazla olmuştur. Bu sefer sıklığı uygulanacak olursa maliyet ve atıl kapasite daha yüksek olacaktır ama yolcular daha konforlu ulaşım imkanına kavuşacaklardır. Bu durum yolcu memnuniyetini arttıracaktır.

ESHOT'un mevcut çizelgesi ve model 14'e göre hesaplanan optimum sefer sıklığına göre düzenlenen çizelgeler Tablo 31'de gösterilmiştir. Hem gidiş hem de dönüş yönündeki sefer sıklığı aynı sayıdadır.

Tablo 31: 63 Nolu Evka 3 Metro – Konak Hattı için ESHOT'un Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge

Hafta İçi				Hafta Sonu			
Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş için Önerilen Çizelge	Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş için Önerilen Çizelge
08:01	08:01	18:00	18:00	08:01	08:01	18:00	18:00
08:08	08:06	18:05	18:05	08:08	08:06	18:05	18:05
08:15	08:12	18:10	18:11	08:15	08:12	18:10	18:11
08:22	08:17	18:15	18:16	08:22	08:17	18:15	18:16
08:29	08:22	18:20	18:22	08:29	08:22	18:20	18:22
08:36	08:28	18:26	18:27	08:36	08:28	18:26	18:27
08:42	08:33	18:33	18:33	08:42	08:33	18:33	18:33
08:48	08:39	18:39	18:38	08:48	08:39	18:39	18:38
08:54	08:44	18:46	18:44	08:54	08:44	18:46	18:44
	08:49	18:52	18:49		08:49	18:52	18:49
	08:55		18:55		08:55		18:55

802 nolu hat için hafta sonu 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 561 yolcudur. Maliyetler hesaba katılırken 23,4 km mesafedeki yakıt tüketimi hesaplanıp mazot fiyatıyla çarpılmış (6 ₺) bir seferin

maliyeti 74,41 ₺ olarak hesaplanmıştır. Hatta 21 körüklü, 3 solo otobüs hizmet vermektedir. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 32’de gösterilmiştir.

Tablo 32: 802 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	11	4	15	17	11	10	10
Sefer Başına Yolcu Sayısı	51	140	37	33	51	56	56
Durakta Bekleme Süresi	5,45	15,00	4,00	3,53	5,45	6,00	6,00
Maliyet	819	298	1.116	1.265	819	744	744
m ² 'ye Düşen Yolcu Sayısı	1,39	3,62	1,03	0,91	1,39	1,53	1,53
Atıl Kapasite	1020	14	1595	1883	1020	877	877
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	11,38	17,50	7,9	6,1	11,4	12,3	12,3
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,63	2,50	1,1	0,9	1,6	1,8	1,8
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		40,8	4.325,1	5.114,0	8.080,7	6.901,0	6.901,0

Tablo 32’deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 6’dır. ESHOT’un mevcut çizelgesinde sefer sıklığını 11 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6’da 15, Model 9’da 17 olarak hesaplanmıştır. Model 6’da bekleme süresinin Model 9’da hem bekleme süresinin hem de m²’ye düşen yolcu sayısı hesaba katılması nedeniyle model 3’e göre daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 6 ve Model 9’dan daha dengeli bir sefer sıklığı olan 11 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m²’ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²’ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Model 13’te m²’ye düşen yolcu sayısı değişkeni model 12’den çıkartılarak elde edilmiştir. Yani bu model pozitif ve negatif sapmaları, durakta bekleme süresini ve maliyeti dikkate almaktadır. Bu modelde optimum sefer sıklığı 10 olarak hesaplanmıştır. Hesaplanan m²’ye düşen yolcu sayısı 2,86’dan düşük olduğu için model 14’te de aynı sonuç elde edilmiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (10) ESHOT’un belirlediği sefer sıklığından (11) bir miktar düşük

olmuştur. Bu durum ESHOT'un yüksek kalite algısını sağlayarak maliyet tasarrufu yapabileceğini göstermiştir.

802 nolu hat için hafta sonu 17:00-17:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 414 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 33'de gösterilmiştir.

Tablo 33: 802 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	11	3	15	17	11	10	10
Sefer Başına Yolcu Sayısı	38	138	28	24	38	41	41
Durakta Bekleme Süresi	5,45	20,00	4,00	3,53	5,45	6,00	6,00
Maliyet	819	223,24	1.116	1.265	819	744	744
m ² 'ye Düşen Yolcu Sayısı	1,00	3,57	0,78	0,66	1,00	1,12	1,12
Atıl Kapasite	1167	17,25	1.742,3	2.029,8	1.167,3	1.023,5	1.023,5
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	11,38	18,38	7,9	6,1	11,4	12,3	12,3
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,63	2,63	1,1	0,9	1,6	1,8	1,8
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		45,9	4.501,5	5.092,7	7.944,6	7.077,4	7.077,4

Tablo 33'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 3'tür. ESHOT'un mevcut çizelgesinde sefer sıklığını 11 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da 15 ve Model 9'da 17 olarak hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 6 ve Model 9'dan daha dengeli bir sefer sıklığı olan 11 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısı ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Model 13'de ve model 14'de m²'ye düşen yolcu sayısı 2,86'dan küçük olduğu için optimum sefer sıklığı 10 olarak hesaplanmıştır. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (10) ESHOT'un belirlediği sefer sıklığından (11) bir miktar düşük olmuştur. Bu durum ESHOT'un yüksek kalite algısını sağlayarak maliyet tasarrufu yapabileceğini göstermiştir.

802 nolu hat için hafta içi 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 494 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 34’de gösterilmiştir.

Tablo 34: 802 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	11	4	15	17	11	10	10
Sefer Başına Yolcu Sayısı	45	124	33	29	45	49	49
Durakta Bekleme Süresi	5,45	15,00	4,00	3,53	5,45	6,00	6,00
Maliyet	819	298	1.116	1.265	819	744	744
m ² 'ye Düşen Yolcu Sayısı	1,22	3,21	0,91	0,79	1,22	1,34	1,34
Atıl Kapasite	1087	81	1662	1950	1087	944	944
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	11,38	17,50	7,9	6,1	11,4	12,3	12,3
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,63	2,50	1,1	0,9	1,6	1,8	1,8
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		121,2	4.405,5	5.100,2	8.025,6	6.981,4	6.981,4

Tablo 34’teki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 4’tür. ESHOT’un mevcut çizelgesinde sefer sıklığını 11 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6’da 15 ve Model 9’da 17 olarak hesaplanmıştır. Model 6’da bekleme süresinin Model 9’da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı hesaba katılması nedeniyle model 3’e göre daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9’dan daha dengeli bir sefer sıklığı olan 11 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Model 13’te optimum sefer sıklığı 10 olarak hesaplanmıştır. Hesaplanan m²'ye düşen yolcu sayısı 2,86’dan küçük olduğundan model 14’te de aynı sonuç elde edilmiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (10) ESHOT’un belirlediği sefer sıklığından (11) bir miktar düşük olmuştur. Bu durum ESHOT’un yüksek kalite algısını sağlayarak maliyet tasarrufu yapabileceğini göstermiştir.

802 nolu hat için hafta içi 17:00-17:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 331 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 35’de gösterilmiştir.

Tablo 35: 802 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	11	3	15	15	10	10	10
Sefer Başına Yolcu Sayısı	30	110	22	22	33	33	33
Durakta Bekleme Süresi	5,45	20,00	4,00	4,00	6,00	6,00	6,00
Maliyet	819	223	1.116	1.116	744	744	744
m ² 'ye Düşen Yolcu Sayısı	0,82	2,85	0,61	0,61	0,90	0,90	0,90
Atıl Kapasite	1250	100	1825	1825	1107	1107	1107
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	11,38	18,38	7,9	7,9	12,3	12,3	12,3
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,63	2,63	1,1	1,1	1,8	1,8	1,8
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		145,5	4.601,1	5.090,7	7.894,1	7.177,0	7.177,0

Tablo 35’teki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 3’tür. ESHOT’un mevcut çizelgesinde sefer sıklığını 11 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6’da ve Model 9’da 15 olarak hesaplanmıştır. Model 6’da bekleme süresinin, Model 9’da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9’dan daha dengeli bir sefer sıklığı olan 10 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısı ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, kişi başına düşen alan, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Model 13’de optimum sefer sıklığı 10 olarak hesaplanmıştır. m²'ye düşen yolcu sayısı 2,86’dan düşük olduğundan model 14’te de optimum sefer sıklığı 10 olarak hesaplanmıştır. Model 4 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (10) ESHOT’un belirlediği sefer sıklığından (11) bir miktar düşük olmuştur. Bu durum ESHOT’un yüksek kalite algısını sağlayarak maliyet tasarrufu yapabileceğini göstermiştir.

ESHOT'un mevcut çizelgesi ve hesaplanan optimum sefer sıklığına göre düzenlenen çizelgeler Tablo 36'da gösterilmiştir. Hem gidiş hem de dönüş yönündeki sefer sıklığı aynı sayıdadır.

Tablo 36: 802 Nolu Egekent Aktarma – Konak Hattı için ESHOT'un Uyguladığı Çizelgeler ile Algoritma Sonucunda Elde Edilen Çizelgeler

Hafta İçi				Hafta Sonu			
Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş için Önerilen Çizelge	Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş için Önerilen Çizelge
07:03	07:03	17:02	17:02	07:03	07:03	17:02	17:02
07:08	07:09	17:07	17:08	07:08	07:09	17:07	17:08
07:13	07:14	17:12	17:14	07:13	07:14	17:12	17:14
07:18	07:20	17:18	17:19	07:18	07:20	17:18	17:19
07:23	07:26	17:23	17:25	07:23	07:26	17:23	17:25
07:28	07:32	17:28	17:31	07:28	07:32	17:28	17:31
07:33	07:37	17:33	17:37	07:33	07:37	17:33	17:37
07:38	07:43	17:38	17:43	07:38	07:43	17:38	17:43
07:43	07:49	17:44	17:48	07:43	07:49	17:44	17:48
07:49	07:54	17:49	17:54	07:49	07:54	17:49	17:54
07:59		17:54		07:59		17:54	

171 nolu hat için hafta sonu sabah 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 1.139 yolcudur. Maliyetler hesaba katılırken 20,1 km mesafedeki yakıt tüketimi hesaplanıp mazot fiyatıyla çarpılmış (6 ₺) bir seferin maliyeti 63,92 ₺ olarak hesaplanmıştır. Hatta 19 körüklü, 3 solo otobüs hizmet vermektedir. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 37'de gösterilmiştir.

Tablo 37: 171 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	12	8	15	18	11	10	11
Sefer Başına Yolcu Sayısı	95	142	76	63	104	114	104
Durakta Bekleme Süresi	5,00	7,50	4,00	3,33	5,45	6,00	5,45
Maliyet	767	511	959	1.151	703	639	703
m ² 'ye Düşen Yolcu Sayısı	2,69	3,96	2,11	1,73	2,79	3,11	2,79
Atıl Kapasite	579	6	1009	1438	436	293	436
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	8,64	12,09	6,0	3,5	9,5	10,4	9,5
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,36	1,91	1,0	0,5	1,5	1,6	1,5
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		145,5	3.618,9	5.114,4	8.152,7	5.883,3	5.918,4

Tablo 37'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 8'dir. ESHOT'un mevcut çizelgesinde sefer sıklığını 12 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da 15 ve Model 9'da 18 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9'dan daha dengeli bir sefer sıklığı olan 11 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m^2 'ye düşen yolcu sayısı ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m^2 'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Mevcut çizelgeye göre bu modelde bekleme süresi, m^2 'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13 pozitif ve negatif sapmaları, durakta bekleme süresini ve maliyeti dikkate almaktadır. Bu modelde sefer sıklığı 10 olarak hesaplanmıştır. Model 14'de optimum sefer sıklığı 11 olarak hesaplanmıştır. Çünkü bu hat için 11'den az sefer sıklığı belirlenirse m^2 'ye düşen yolcu sayısı 2,86'dan büyük olur ki bu durum sistem kısıtının ihlal edilmesi anlamına gelmektedir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (12) bir miktar düşük olmuştur. Bu durum ESHOT'un yüksek kalite algısını sağlayarak maliyet tasarrufu yapabileceğini göstermiştir.

171 nolu hat için hafta sonu sabah 18:00-18:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 508 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 38'de gösterilmiştir.

Tablo 38: 171 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	8	4	15	17	11	10	10
Sefer Başına Yolcu Sayısı	64	127	34	30	46	51	51
Durakta Bekleme Süresi	7,50	15,00	4,00	3,53	5,45	6,00	6,00
Maliyet	511	256	959	1.087	703	639	639
m ² 'ye Düşen Yolcu Sayısı	1,77	3,74	0,95	0,83	1,25	1,39	1,39
Atıl Kapasite	637	65	1640	1926	1067	924	924
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	12,09	15,55	6,0	4,3	9,5	10,4	10,4
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,91	2,45	1,0	0,7	1,5	1,6	1,6
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		99,3	4.376,1	5.101,5	7.673,2	6.640,5	6.640,5

Tablo 38'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 8'dir. ESHOT'un mevcut çizelgesinde sefer sıklığını 12 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da 15 ve Model 9'da 17 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9'dan daha dengeli bir sefer sıklığı olan 11 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Mevcut çizelgeye göre bu modelde bekleme süresi, m²'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13'de optimum sefer sıklığı 10 olarak hesaplanmıştır. Bu modelde m²'ye düşen yolcu sayısı 2,86'dan düşük olduğu için model 14 aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (10) ESHOT'un belirlediği sefer sıklığından (8) bir miktar yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

171 nolu hat için hafta içi sabah 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 840 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 39'da gösterilmiştir.

Tablo 39: 171 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	12	6	15	18	11	10	10
Sefer Başına Yolcu Sayısı	70	140	56	47	76	84	84
Durakta Bekleme Süresi	5,00	10,00	4,00	3,33	5,45	6,00	6,00
Maliyet	767	384	959	1.151	703	639	639
m ² 'ye Düşen Yolcu Sayısı	1,98	3,95	1,55	1,26	2,07	2,29	2,29
Atıl Kapasite	878	19	1308	1737	735	592	592
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	8,64	13,82	6,0	3,5	9,5	10,4	10,4
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,36	2,18	1,0	0,5	1,5	1,6	1,6
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		42,1	3.977,7	5.098,6	7.929,9	6.242,1	6.242,1

Tablo 39'daki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 6'dır. ESHOT'un mevcut çizelgesinde sefer sıklığını 12 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da 15 ve Model 9'da 18 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9'dan daha dengeli bir sefer sıklığı olan 11 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Mevcut çizelgeye göre bu modelde bekleme süresi, m²'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13 pozitif ve negatif sapmaları, durakta bekleme süresini ve maliyeti dikkate almaktadır. Bu modelde optimum sefer sıklığı 10 olarak hesaplanmıştır. Hesaplanan m²'ye düşen yolcu sayısı 2,86'dan düşük olduğu için model 14'de de aynı sonuç elde edilmiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (10) ESHOT'un belirlediği sefer sıklığından (12) bir miktar düşük olmuştur. Bu durum ESHOT'un yüksek kalite algısını sağlayarak maliyet tasarrufu yapabileceğini göstermiştir.

171 nolu hat için hafta içi akşam 18:00-18:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 416 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 40’da gösterilmiştir.

Tablo 40: 171 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	8	3	15	16	11	10	10
Sefer Başına Yolcu Sayısı	52	139	28	26	38	42	42
Durakta Bekleme Süresi	7,50	20,00	4,00	3,75	5,45	6,00	6,00
Maliyet	511	192	959	1.023	703	639	639
m ² 'ye Düşen Yolcu Sayısı	1,47	3,60	0,78	0,72	1,00	1,12	1,12
Atıl Kapasite	729	14	1732	1875	1159	1016	1016
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	12,09	16,41	6,0	5,2	9,5	10,4	10,4
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,91	2,59	1,0	0,8	1,5	1,6	1,6
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		39,1	4.486,5	5.079,4	7.586,0	6.750,9	6.750,9

Tablo 40’daki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 3’tür. ESHOT’un mevcut çizelgesinde sefer sıklığını 8 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6’da 15 ve Model 9’da 16 olarak hesaplanmıştır. Model 6’da bekleme süresinin, model 9’da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9’dan daha dengeli bir sefer sıklığı olan 11 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Mevcut çizelgeye göre bu modelde bekleme süresi, m²'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13’de optimum sefer sıklığı 10 olarak hesaplanmıştır. Hesaplanan m²'ye düşen yolcu sayısı 2,86’dan düşük olduğu için model 14’de aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (10) ESHOT’un belirlediği sefer sıklığından (8) bir miktar yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

ESHOT'un mevcut çizelgesi ve hesaplanan optimum sefer sıklığına göre düzenlenen çizelgeler Tablo 41'de gösterilmiştir. Hem gidiş hem de dönüş yönündeki sefer sıklığı aynı sayıdadır.

Tablo 41: ESHOT'un 171 Nolu Tınaztepe – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge

Hafta İçi				Hafta Sonu			
Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş İçin Önerilen Çizelge	Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş İçin Önerilen Çizelge
07:02	07:02	18:01	18:01	07:02	07:02	18:01	18:01
07:08	07:08	18:09	18:07	07:08	07:07	18:09	18:07
07:12	07:14	18:17	18:13	07:12	07:13	18:17	18:13
07:16	07:19	18:25	18:19	07:16	07:18	18:25	18:19
07:20	07:25	18:33	18:25	07:20	07:23	18:33	18:25
07:24	07:31	18:41	18:31	07:24	07:28	18:41	18:31
07:28	07:37	18:49	18:36	07:28	07:34	18:49	18:36
07:32	07:43	18:57	18:42	07:32	07:39	18:57	18:42
07:36	07:49		18:48	07:36	07:44		18:48
07:42	07:54		18:54	07:42	07:49		18:54
07:48				07:48	07:55		
07:54				07:54			

554 nolu Narlıdere – Konak hattı için hafta sonu 16:00-16:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 669 yolcudur. Maliyetler hesaba katılırken 24,3 km mesafedeki yakıt tüketimi hesaplanıp mazot fiyatıyla çarpılmış (6 ₺) bir seferin maliyeti 77,27 ₺ olarak hesaplanmıştır. Hatta 12 körüklü, 1 solo otobüs hizmet vermektedir. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 42'de gösterilmiştir.

Tablo 42: 554 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	4	5	13	13	11	9	9
Sefer Başına Yolcu Sayısı	167	134	51	51	61	74	74
Durakta Bekleme Süresi	15,00	12,00	4,62	4,62	5,45	6,67	6,67
Maliyet	309	386	1.005	1.005	850	695	695
m ² 'ye Düşen Yolcu Sayısı	4,32	3,47	1,40	1,40	1,66	2,03	2,03
Atıl Kapasite	0	62	1231	1231	939	646	646
Eksik Kapasite	84,38	0,00	0	0	0	0	0
Atıl zaman Körüklü	8,31	7,38	0,0	0,0	1,8	3,7	3,7
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,69	0,62	0,0	0,0	0,2	0,3	0,3
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		83,7	4.246,4	5.368,2	8.282,5	6.866,9	6.866,9

Tablo 42'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de hesaplanan sefer sıklığı 5'dir. ESHOT'un bu dönemde daha düşük bir sefer sıklığını (4) uyguladığı görülmüştür. ESHOT'un uyguladığı çizelge maliyet ve verimlilik açısından daha iyi olabilir. Ancak, durakta bekleme süresi ve m^2 'ye düşen yolcu sayısı daha fazladır. Bu kalite algısını olumsuz etkilemektedir. Optimum sefer sıklığı Model 6'da ve Model 9'da 13 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9'dan daha dengeli bir sefer sıklığı olan 11 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m^2 'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m^2 'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Model 13'te optimum sefer sıklığı 9 olarak hesaplanmıştır. Hesaplanan m^2 'ye düşen yolcu sayısı 2,86'dan düşük olduğundan model 14 aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (9) ESHOT'un belirlediği sefer sıklığından (4) bir miktar yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

554 nolu hat için hafta sonu 18:00-18:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 387 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 43'de gösterilmiştir.

Tablo 43: 554 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	6	3	13	13	11	9	9
Sefer Başına Yolcu Sayısı	65	129	30	30	35	43	43
Durakta Bekleme Süresi	10,00	20,00	4,62	4,62	5,45	6,67	6,67
Maliyet	464	232	1.005	1.005	850	695	695
m^2 'ye Düşen Yolcu Sayısı	1,68	3,34	0,78	0,78	0,95	1,18	1,18
Atıl Kapasite	490	51	1513	1513	1221	928	928
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	6,46	9,23	0,0	0,0	1,8	3,7	3,7
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,54	0,77	0,0	0,0	0,2	0,3	0,3
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		73,8	4.584,8	5.207,8	8.048,6	7.205,3	7.205,3

Tablo 43'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 3'tür. ESHOT'un mevcut çizelgesinde sefer sıklığını 6 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da ve Model 9'da 13 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9'dan daha dengeli bir sefer sıklığı olan 11 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m^2 'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m^2 'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Model 13'de optimum sefer sıklığı 9 olarak hesaplanmıştır. Hesaplanan m^2 'ye düşen yolcu sayısı 2,86'dan küçük olduğu için model 14 aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (9) ESHOT'un belirlediği sefer sıklığından (6) bir miktar yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

554 nolu hat için hafta içi 16:00-16:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 824 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 44'de gösterilmiştir.

Tablo 44: 554 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	6	6	13	13	12	9	9
Sefer Başına Yolcu Sayısı	137	137	63	63	69	92	92
Durakta Bekleme Süresi	10,00	10,00	4,62	4,62	5,00	6,67	6,67
Maliyet	464	464	1.005	1.005	927	695	695
m^2 'ye Düşen Yolcu Sayısı	3,54	3,54	1,73	1,73	1,87	2,50	2,50
Atıl Kapasite	53	53	1076	1076	930	491	491
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	6,46	6,46	0,0	0,0	0,9	3,7	3,7
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,54	0,54	0,0	0,0	0,1	0,3	0,3
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		71,9	4.060,4	5.442,0	8.395,3	6.680,9	6.680,9

Tablo 44'teki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de hesaplanan sefer sıklığı 6'dır. Bu değer ESHOT'un uyguladığı sefer sıklığıdır. Optimum sefer sıklığı Model 6'da ve Model 9'da 13 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9'dan daha dengeli bir sefer sıklığı olan 12 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m^2 'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m^2 'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Model 13'te optimum sefer sıklığı 9 olarak hesaplanmıştır. Hesaplanan m^2 'ye düşen yolcu sayısı 2,86'dan küçük olduğu için model 14 aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (9) ESHOT'un belirlediği sefer sıklığından (6) bir miktar yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

554 nolu hat için hafta içi 18:00-18:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 340 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 45'te gösterilmiştir.

Tablo 45: 554 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	6	3	13	13	10	9	9
Sefer Başına Yolcu Sayısı	57	113	26	26	34	38	38
Durakta Bekleme Süresi	10,00	20,00	4,62	4,62	6,00	6,67	6,67
Maliyet	464	232	1.005	1.005	773	695	695
m^2 'ye Düşen Yolcu Sayısı	1,47	2,92	0,70	0,70	0,92	1,04	1,04
Atıl Kapasite	537	98	1560	1560	1122	975	975
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	6,46	9,23	0,0	0,0	2,8	3,7	3,7
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,54	0,77	0,0	0,0	0,2	0,3	0,3
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		130,2	4.641,2	5.202,1	8.005,5	7.261,7	7.261,7

Tablo 45'teki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 3'tür. ESHOT'un mevcut çizelgesinde sefer sıklığını 6 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını

göstermektedir. Optimum sefer sıklığı Model 6’da ve Model 9’da 13 olarak hesaplanmıştır. Model 6’da bekleme süresinin, model 9’da hem bekleme süresinin hem de m^2 ’ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9’dan daha dengeli bir sefer sıklığı olan 10 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m^2 ’ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m^2 ’ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Model 13’de optimum sefer sıklığı 9 olarak hesaplanmıştır. Hesaplanan m^2 ’ye düşen yolcu sayısı 2,86’dan küçük olduğundan model 14’de aynı sonuç elde edilmiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (9) ESHOT’un belirlediği sefer sıklığından (6) bir miktar yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

ESHOT’un mevcut çizelgesi ve hesaplanan optimum sefer sıklığına göre düzenlenen çizelgeler Tablo 46’da gösterilmiştir. Hem gidiş hem de dönüş yönündeki sefer sıklığı aynı sayıdadır.

Tablo 46: ESHOT’un 554 Nolu Narlıdere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge

Hafta İçi				Hafta Sonu			
Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş İçin Önerilen Çizelge	Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş İçin Önerilen Çizelge
17:01	17:01	18:01	18:01	16:09	16:09	18:01	18:01
17:12	17:08	18:12	18:08	16:23	16:15	18:12	18:08
17:23	17:14	18:23	18:14	16:36	16:20	18:23	18:14
17:34	17:21	18:34	18:21	16:50	16:26	18:34	18:21
17:45	17:27	18:45	18:27		16:32	18:45	18:27
17:56	17:34	18:56	18:34		16:37	18:56	18:34
	17:40		18:40		16:43		18:40
	17:47		18:47		16:49		18:47
	17:53		18:53		16:54		18:53

169 nolu Balçova – Konak hattı için hafta sonu 15:00-15:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 389 yolcudur. Maliyetler hesaba katılırken 12,4 km mesafedeki yakıt tüketimi hesaplanıp mazot fiyatıyla çarpılmış (6

₺) bir seferin maliyeti 39,43 ₺ olarak hesaplanmıştır. Hatta 13 körüklü, 0 solo otobüs hizmet vermektedir. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 47’de gösterilmiştir.

Tablo 47: 169 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	3	13	13	12	11	11
Sefer Başına Yolcu Sayısı	78	130	30	30	32	35	35
Durakta Bekleme Süresi	12,00	20,00	4,62	4,62	5,00	5,45	5,45
Maliyet	197	118	513	513	473	434	434
m ² 'ye Düşen Yolcu Sayısı	2,02	3,36	0,78	0,78	0,83	0,91	0,91
Atıl Kapasite	361	61	1561	1561	1411	1261	1261
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	8,00	10,00	0,0	0,0	1,0	2,0	2,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		85,2	4.642,4	5.263,2	6.776,1	6.089,6	6.089,6

Tablo 47’deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 3’tür. ESHOT’un mevcut çizelgesinde sefer sıklığını 5 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6’da ve Model 9’da 13 olarak hesaplanmıştır. Model 6’da bekleme süresinin, model 9’da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9’dan daha dengeli bir sefer sıklığı olan 12 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Model 13’te optimum sefer sıklığı 11 olarak hesaplanmıştır. Hesaplanan m²'ye düşen yolcu sayısı 2,86’dan düşük olduğundan model 14’de aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (9) ESHOT’un belirlediği sefer sıklığından (5) bir miktar yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

169 nolu hat için hafta sonu 17:00-17:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 275 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 48’de gösterilmiştir.

Tablo 48: 169 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	2	13	13	12	11	11
Sefer Başına Yolcu Sayısı	55	138	21	21	23	25	25
Durakta Bekleme Süresi	12,00	30,00	4,62	4,62	5,00	5,45	5,45
Maliyet	197	79	513	513	473	434	434
m ² 'ye Düşen Yolcu Sayısı	1,42	3,57	0,54	0,54	0,59	0,65	0,65
Atıl Kapasite	475	25	1675	1675	1525	1375	1375
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	8,00	11,00	0,0	0,0	1,0	2,0	2,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		43,2	4.779,2	5.213,8	6.726,7	6.226,4	6.226,4

Tablo 48’deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 2’dir. ESHOT’un mevcut çizelgesinde sefer sıklığını 5 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6’da ve Model 9’da 13 olarak hesaplanmıştır. Model 6’da bekleme süresinin, model 9’da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9’dan daha dengeli bir sefer sıklığı olan 12 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. m²'ye düşen yolcu sayısı 2,86’dan düşük olduğundan model 13’de ve model 14’de optimum sefer sıklığı 11 olarak hesaplanmıştır. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT’un belirlediği sefer sıklığından (5) önemli ölçüde yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

169 nolu hat için hafta içi 15:00-15:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 384 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 49’da gösterilmiştir.

Tablo 49: 169 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	3	13	13	12	11	11
Sefer Başına Yolcu Sayısı	77	128	30	30	32	35	35
Durakta Bekleme Süresi	12,00	20,00	4,62	4,62	5,00	5,45	5,45
Maliyet	197	118	513	513	473	434	434
m ² 'ye Düşen Yolcu Sayısı	1,99	3,31	0,78	0,78	0,83	0,91	0,91
Atıl Kapasite	366	66	1566	1566	1416	1266	1266
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	8,00	10,00	0,0	0,0	1,0	2,0	2,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		91,2	4.648,4	5.269,2	6.782,1	6.095,6	6.095,6

Tablo 49’daki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 3’tür. ESHOT’un mevcut çizelgesinde sefer sıklığını 5 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6’da ve Model 9’da 13 olarak hesaplanmıştır. Model 6’da bekleme süresinin, model 9’da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9’dan daha dengeli bir sefer sıklığı olan 12 değerini hesaplamıştır. Bu değer sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. m²'ye düşen yolcu sayısı 2,86’dan düşük olduğundan Model 13’te ve model 14’te optimum sefer sıklığı 11 olarak hesaplanmıştır. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT’un belirlediği sefer sıklığından (5) önemli ölçüde yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

169 nolu hat için hafta içi akşam 17:00-17:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 208 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 50’de gösterilmiştir.

Tablo 50: 169 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	2	13	13	12	11	11
Sefer Başına Yolcu Sayısı	42	104	16	16	17	19	19
Durakta Bekleme Süresi	12,00	30,00	4,62	4,62	5,00	5,45	5,45
Maliyet	197	79	513	513	473	434	434
m ² 'ye Düşen Yolcu Sayısı	1,09	2,69	0,41	0,41	0,44	0,49	0,49
Atıl Kapasite	542	92	1742	1742	1592	1442	1442
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	8,00	11,00	0,0	0,0	1,0	2,0	2,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		123,6	4.859,6	5.190,7	6.682,9	6.306,8	6.306,8

Tablo 50’deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 2’dir. ESHOT’un mevcut çizelgesinde sefer sıklığını 5 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6’da ve Model 9’da 13 olarak hesaplanmıştır. Model 6’da bekleme süresinin, model 9’da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate aldığı için Model 3 ve Model 9’dan daha dengeli bir sefer sıklığı olan 12 değerini hesaplamıştır. Bu değer sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. m²'ye düşen yolcu sayısı 2,86’dan düşük olduğu için model 13’de ve model 14’de optimum sefer sıklığı 11 olarak hesaplanmıştır. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT’un belirlediği sefer sıklığından (5) önemli ölçüde yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

ESHOT'un mevcut çizelgesi ve hesaplanan optimum sefer sıklığına göre düzenlenen çizelgeler Tablo 51'de gösterilmiştir. Hem gidiş hem de dönüş yönündeki sefer sıklığı aynı sayıdadır.

Tablo 51: ESHOT'un 169 Nolu Narlıdere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge

Hafta İçi				Hafta Sonu			
Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş İçin Önerilen Çizelge	Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş İçin Önerilen Çizelge
15:11	15:11	17:08	17:08	15:11	15:11	17:08	17:08
15:22	15:15	17:19	17:13	15:22	15:15	17:19	17:13
15:34	15:20	17:30	17:17	15:34	15:20	17:30	17:17
15:45	15:24	17:42	17:22	15:45	15:24	17:42	17:22
15:57	15:29	17:53	17:27	15:57	15:29	17:53	17:27
	15:33		17:32		15:33		17:32
	15:38		17:36		15:38		17:36
	15:42		17:41		15:42		17:41
	15:47		17:46		15:47		17:46
	15:51		17:51		15:51		17:51
	15:56		17:56		15:56		17:56

23 nolu Uzundere – Konak hattı için hafta sonu sabah 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 1.039 yolcudur. Maliyetler hesaba katılırken 8,9 km mesafedeki yakıt tüketimi hesaplanıp mazot fiyatıyla çarpılmış (6 ₺) bir seferin maliyeti 28,30 ₺ olarak hesaplanmıştır. Hatta 15 körüklü, 3 solo otobüs hizmet vermektedir. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 52'de gösterilmiştir.

Tablo 52: 23 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	11	8	15	18	15	12	12
Sefer Başına Yolcu Sayısı	94	130	69	58	69	87	87
Durakta Bekleme Süresi	5,45	7,50	4,00	3,33	4,00	5,00	5,00
Maliyet	311	226	425	509	425	340	340
m ² 'ye Düşen Yolcu Sayısı	2,67	3,59	1,91	1,64	1,91	2,42	2,42
Atıl Kapasite	519	94	1086	1511	1086	661	661
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	5,83	8,33	2,5	0,0	2,5	5,0	5,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,17	1,67	0,5	0,0	0,5	1,0	1,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		125,2	3.706,8	5.127,7	6.511,1	4.819,3	4.819,3

Tablo 52'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 8'dir. ESHOT'un mevcut çizelgesinde sefer sıklığını 11 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da 15 ve Model 9'da 18 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de optimum sefer sıklığı 15 olarak hesaplanmıştır. Bu model sapmaları, bekleme süresini, m^2 'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m^2 'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Mevcut çizelgeye göre bu modelde bekleme süresi, m^2 'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13'te optimum sefer sıklığı 12 olarak hesaplanmıştır. Hesaplanan m^2 'ye düşen yolcu sayısı 2,86'dan küçük olduğundan model 14'de aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (12) ESHOT'un belirlediği sefer sıklığından (11) biraz yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

23 nolu hat için hafta sonu akşam üzeri 18:00-18:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 776 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 53'de gösterilmiştir.

Tablo 53: 23 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	6	6	15	18	15	12	12
Sefer Başına Yolcu Sayısı	129	129	52	43	52	65	65
Durakta Bekleme Süresi	10,00	10,00	4,00	3,33	4,00	5,00	5,00
Maliyet	170	170	425	509	425	340	340
m^2 'ye Düşen Yolcu Sayısı	3,68	3,68	1,45	1,21	1,45	1,84	1,84
Atıl Kapasite	74	74	1349	1774	1349	924	924
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	10,00	10,00	2,5	0,0	2,5	5,0	5,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	2,00	2,00	0,5	0,0	0,5	1,0	1,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		103,2	4.022,4	5.098,6	6.452,1	5.134,9	5.134,9

Tablo 53'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de hesaplanan sefer sıklığı 6'dır ve bu değer ESHOT'un uyguladığı sefer sayısına eşittir. Optimum sefer sıklığı Model 6'da 15 ve Model 9'da 18 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de optimum sefer sıklığı 15 olarak hesaplanmıştır. Model 13'de optimum sefer sıklığı 12 olarak hesaplanmıştır. Hesaplanan m^2 'ye düşen yolcu sayısı 2,86'dan düşük olduğundan model 14'de aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (12) ESHOT'un belirlediği sefer sıklığından (6) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

23 nolu hat için hafta içi sabah 07:00 - 07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 786 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 54'de gösterilmiştir.

Tablo 54: 23 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	11	6	15	18	15	12	12
Sefer Başına Yolcu Sayısı	71	131	52	44	52	66	66
Durakta Bekleme Süresi	5,45	10,00	4,00	3,33	4,00	5,00	5,00
Maliyet	311	170	425	509	425	340	340
m^2 'ye Düşen Yolcu Sayısı	2,02	3,70	1,45	1,21	1,45	1,86	1,86
Atıl Kapasite	772	64	1339	1764	1339	914	914
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	5,83	10,00	2,5	0,0	2,5	5,0	5,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,17	2,00	0,5	0,0	0,5	1,0	1,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		91,2	4.010,4	5.086,6	6.440,1	5.122,9	5.122,9

Tablo 54'teki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 6'dır. ESHOT'un mevcut çizelgesinde sefer sıklığını 11 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da 15 ve Model 9'da 18 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle

daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12’de optimum sefer sıklığı 15 olarak hesaplanmıştır. Bu model sapmaları, bekleme süresini, m²’ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²’ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Mevcut çizelgeye göre bu modelde bekleme süresi, m²’ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13’te optimum sefer sıklığı 12 olarak hesaplanmıştır. Hesaplanan m²’ye düşen yolcu sayısı 2,86’dan düşük olduğu için model 14’de aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (12) ESHOT’un belirlediği sefer sıklığından (11) biraz yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

23 nolu hat için hafta içi 18:00-18:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 639 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 55’te gösterilmiştir.

Tablo 55: 23 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	6	5	15	18	14	12	12
Sefer Başına Yolcu Sayısı	107	128	43	36	46	53	53
Durakta Bekleme Süresi	10,00	12,00	4,00	3,33	4,29	5,00	5,00
Maliyet	170	142	425	509	396	340	340
m ² ’ye Düşen Yolcu Sayısı	3,02	3,68	1,20	1,02	1,29	1,50	1,50
Atıl Kapasite	211	69	1486	1911	1344	1061	1061
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	10,00	10,83	2,5	0,0	3,3	5,0	5,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	2,00	2,17	0,5	0,0	0,7	1,0	1,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		91,2	4.186,8	5.106,8	6.410,0	5.299,3	5.299,3

Tablo 55’teki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 5’dir. ESHOT’un mevcut çizelgesinde sefer sıklığını 6 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6’da 15 ve Model 9’da 18 olarak hesaplanmıştır. Model 6’da bekleme süresinin, model 9’da hem bekleme süresinin hem de m²’ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12 ulaşımın yakıt maliyetini de dikkate

aldığı için Model 3 ve Model 9'dan daha dengeli bir sefer sıklığı olan 14 değerini hesaplamıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Bu nedenle bekleme süresi, m²'ye düşen yolcu sayısı ve maliyet değerlerinin model 3 ile model 9 arasında yer aldığı görülmektedir. Mevcut çizelgeye göre bu modelde bekleme süresi, m²'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13'de optimum sefer sıklığı 12 olarak hesaplanmıştır. Hesaplanan m²'ye düşen yolcu sayısı 2,86'dan küçük olduğu için model 14'de aynı sonuç elde edilmiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (12) ESHOT'un belirlediği sefer sıklığından (6) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

ESHOT'un mevcut çizelgesi ve hesaplanan optimum sefer sıklığına göre düzenlenen çizelgeler Tablo 56'da gösterilmiştir. Hem gidiş hem de dönüş yönündeki sefer sıklığı aynı sayıdadır.

Tablo 56: ESHOT'un 23 Nolu Narlıdere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge

Hafta İçi				Hafta Sonu			
Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş için önerilen Çizelge	Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş için önerilen Çizelge
07:00	07:00	18:01	18:01	07:00	07:00	18:01	18:01
07:10	07:05	18:12	18:06	07:10	07:05	18:12	18:06
07:15	07:10	18:23	18:11	07:15	07:10	18:23	18:11
07:20	07:15	18:34	18:16	07:20	07:15	18:34	18:16
07:25	07:20	18:45	18:21	07:25	07:20	18:45	18:21
07:30	07:25	18:56	18:26	07:30	07:25	18:56	18:26
07:35	07:30		18:31	07:35	07:30		18:31
07:40	07:35		18:35	07:40	07:35		18:35
07:45	07:40		18:40	07:45	07:40		18:40
07:50	07:45		18:45	07:50	07:45		18:45
07:55	07:50		18:50	07:55	07:50		18:50
	07:55		18:55		07:55		18:55

285 nolu Evka 1 – Konak hattı için hafta sonu 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 1.096 yolcudur. Maliyetler hesaba katılırken 14,94 km mesafedeki yakıt tüketimi hesaplanıp mazot fiyatıyla çarpılmış (6 ₺) bir seferin maliyeti 47,51 ₺ olarak hesaplanmıştır. Hatta 11 körüklü, 1 solo otobüs

hizmet vermektedir. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 57’de gösterilmiştir.

Tablo 57: 285 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	8	12	12	12	11	11
Sefer Başına Yolcu Sayısı	219	137	91	91	91	100	100
Durakta Bekleme Süresi	12,00	7,50	5,00	5,00	5,00	5,45	5,45
Maliyet	238	380	570	570	570	523	523
m ² 'ye Düşen Yolcu Sayısı	5,66	3,79	2,49	2,49	2,49	2,72	2,72
Atıl Kapasite	0	71	654	654	654	508	508
Eksik Kapasite	366,83	0,00	0	0	0	0	0
Atıl zaman Körüklü	6,42	3,67	0,0	0,0	0,0	0,9	0,9
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,58	0,33	0,0	0,0	0,0	0,1	0,1
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		89,6	3.784,8	5.780,1	7.490,4	5.451,5	5.451,5

Tablo 57’deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de hesaplanan sefer sıklığı 8’dir ve bu değer ESHOT’un uyguladığı sefer sayısından daha fazladır. Bu durumda maliyet artarken, yolcuların durakta bekleme süreleri ve m²'ye düşen yolcu sayısı azalmaktadır. ESHOT’un mevcut çizelgesine göre otobüslerin atıl kapasitesi daha yüksek, atıl zamanları daha düşük olacaktır. Optimum sefer sıklığı Model 6’da ve Model 9’da 12 olarak hesaplanmıştır. Model 6’da bekleme süresinin, model 9’da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12’de optimum sefer sıklığı 12 olarak hesaplanmıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısı ve maliyeti minimize etmeye çalışmaktadır. Mevcut çizelgeye göre bu modelde bekleme süresi, m²'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13’te optimum sefer sıklığı 11 olarak hesaplanmıştır. Hesaplanan m²'ye düşen yolcu sayısı 2,86’dan düşük olduğu için Model 14’te aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT’un belirlediği sefer sıklığından (5) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

285 nolu hat için hafta sonu 18:00-18:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 665 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 58’de gösterilmiştir.

Tablo 58: 285 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	4	5	12	12	12	11	11
Sefer Başına Yolcu Sayısı	166	133	55	55	55	60	60
Durakta Bekleme Süresi	15,00	12,00	5,00	5,00	5,00	5,45	5,45
Maliyet	190	238	570	570	570	523	523
m ² 'ye Düşen Yolcu Sayısı	4,29	3,44	1,52	1,52	1,52	1,62	1,62
Atıl Kapasite	0	64	1085	1085	1085	939	939
Eksik Kapasite	81,67	0,00	0	0	0	0	0
Atıl zaman Körüklü	7,33	6,42	0,0	0,0	0,0	0,9	0,9
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,67	0,58	0,0	0,0	0,0	0,1	0,1
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		85,4	4.302,0	5.518,0	7.228,3	5.968,7	5.968,7

Tablo 58’deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de hesaplanan sefer sıklığı 5’dir ve bu değer ESHOT’un uyguladığı sefer sayısından daha yüksektir. Bu durumda maliyet artarken, yolcuların durakta bekleme süreleri ve m²'ye düşen yolcu sayısı azalmaktadır. ESHOT’un mevcut çizelgesine göre otobüslerin atıl kapasitesi daha yüksek, atıl zamanları daha az olacaktır. Optimum sefer sıklığı Model 6’da ve Model 9’da 12 olarak hesaplanmıştır. Model 6’da bekleme süresinin, model 9’da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12’de optimum sefer sıklığı 12 hesaplanmıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Mevcut çizelgeye göre bu modelde bekleme süresi, m²'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13’de optimum sefer sıklığı 11 olarak hesaplanmıştır. Hesaplanan m²'ye düşen yolcu sayısı 2,86’dan düşük olduğundan model 14’de aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT’un belirlediği sefer sıklığından (4) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

285 nolu hat için hafta içi 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 820 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 59’da gösterilmiştir.

Tablo 59: 285 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	6	12	12	12	11	11
Sefer Başına Yolcu Sayısı	164	137	68	68	68	75	75
Durakta Bekleme Süresi	12,00	10,00	5,00	5,00	5,00	5,45	5,45
Maliyet	238	285	570	570	570	523	523
m ² 'ye Düşen Yolcu Sayısı	4,24	3,54	1,87	1,87	1,87	2,04	2,04
Atıl Kapasite	0	55	930	930	930	784	784
Eksik Kapasite	90,83	0,00	0	0	0	0	0
Atıl zaman Körüklü	6,42	5,50	0,0	0,0	0,0	0,9	0,9
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,58	0,50	0,0	0,0	0,0	0,1	0,1
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		85,4	4.116,0	5.612,4	7.322,8	5.782,7	5.782,7

Tablo 59’deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de hesaplanan sefer sıklığı 6’dır ve bu değer ESHOT’un uyguladığı sefer sayısından fazladır. Optimum sefer sıklığı Model 6’da ve Model 9’da 12 olarak hesaplanmıştır. Model 6’da bekleme süresinin, model 9’da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12’de optimum sefer sıklığı 12 hesaplanmıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Mevcut çizelgeye göre bu modelde bekleme süresi, m²'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13’te optimum sefer sıklığı 11 olarak hesaplanmıştır. Hesaplanan m²'ye düşen yolcu sayısı 2,86’dan küçük olduğu için model 14’de aynı sonuç elde edilmiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT’un belirlediği sefer sıklığından (5) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

285 nolu hat için hafta içi 18:00-18:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 589 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 60’da gösterilmiştir.

Tablo 60: 285 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	4	5	12	12	12	11	11
Sefer Başına Yolcu Sayısı	147	118	49	49	49	54	54
Durakta Bekleme Süresi	15,00	12,00	5,00	5,00	5,00	5,45	5,45
Maliyet	190	237,55	570	570	570	523	523
m ² 'ye Düşen Yolcu Sayısı	3,80	3,05	1,32	1,32	1,32	1,47	1,47
Atıl Kapasite	0	140,17	1.161,0	1.161,0	1.161,0	1.015,2	1.015,2
Eksik Kapasite	5,67	0,00	0	0	0	0	0
Atıl zaman Körüklü	7,33	6,42	0,0	0,0	0,0	0,9	0,9
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,67	0,58	0,0	0,0	0,0	0,1	0,1
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		176,6	4.393,2	5.452,9	7.163,2	6.059,9	6.059,9

Tablo 60'daki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de hesaplanan sefer sıklığı 5'tir ve bu değer ESHOT'un uyguladığı sefer sayısından fazladır. Optimum sefer sıklığı Model 6'da ve Model 9'da 12 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de optimum sefer sıklığı 12 olarak hesaplanmıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Mevcut çizelgeye göre bu modelde bekleme süresi, m²'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13'de optimum sefer sıklığı 11 olarak hesaplanmıştır. Hasaplanan m²'ye düşen yolcu sayısı 2,86'dan düşük olduğundan model 14 aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (4) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

ESHOT'un mevcut çizelgesi ve hesaplanan optimum sefer sıklığına göre düzenlenen çizelgeler Tablo 61'de gösterilmiştir. Hem gidiş hem de dönüş yönündeki sefer sıklığı aynı sayıdadır.

Tablo 61: ESHOT'un 285 Nolu Narlıdere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge

Hafta İçi				Hafta Sonu			
Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş İçin Önerilen Çizelge	Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş İçin Önerilen Çizelge
07:09	07:09	18:08	18:08	07:09	07:09	18:08	18:08
07:20	07:14	18:21	18:13	07:20	07:14	18:21	18:13
07:31	07:18	18:34	18:17	07:31	07:18	18:34	18:17
07:42	07:23	18:47	18:22	07:42	07:23	18:47	18:22
07:53	07:28		18:27	07:53	07:28		18:27
	07:32		18:32		07:32		18:32
	07:37		18:36		07:37		18:36
	07:41		18:41		07:41		18:41
	07:46		18:46		07:46		18:46
	07:51		18:51		07:51		18:51
	07:55		18:55		07:55		18:55

193 nolu Yurtoğlu – Konak hattı için hafta sonu 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 1.209 yolcudur. Maliyetler hesaba katılırken 12,1 km mesafedeki yakıt tüketimi hesaplanıp mazot fiyatıyla çarpılmış (6 ₺) bir seferin maliyeti 38,48 ₺ olarak hesaplanmıştır. Hatta 11 körüklü, 2 solo otobüs hizmet vermektedir. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 62’de gösterilmiştir.

Tablo 62: 193 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	9	13	13	13	11	12
Sefer Başına Yolcu Sayısı	242	134	93	93	93	110	101
Durakta Bekleme Süresi	12,00	6,67	4,62	4,62	4,62	5,45	5,00
Maliyet	192	346	500	500	500	423	462
m ² 'ye Düşen Yolcu Sayısı	6,92	3,68	2,61	2,61	2,61	3,13	2,85
Atıl Kapasite	0	72	641	641	641	356	499
Eksik Kapasite	497,46	0,00	0	0	0	0	0
Atıl zaman Körüklü	6,77	3,38	0,0	0,0	0,0	1,7	0,8
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,23	0,62	0,0	0,0	0,0	0,3	0,2
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		90,9	3.538,4	5.623,0	7.123,6	4.972,6	4.984,8

Tablo 62’deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de hesaplanan sefer sıklığı 9’dur ve bu değer ESHOT’un uyguladığı sefer sayısından çok daha fazladır. Bu durumda maliyet artarken, yolcuların durakta bekleme süreleri

ve m^2 'ye düşen yolcu sayısı azalmaktadır. ESHOT'un mevcut çizelgesine göre otobüslerin atıl kapasitesi daha yüksek, atıl zamanları daha az olacaktır. Optimum sefer sıklığı Model 6'da ve Model 9'da 13 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de optimum sefer sıklığı 13 olarak hesaplanmıştır. Model 13'te optimum sefer sıklığı 11 olarak hesaplanmıştır. Model 13'te hesaplanan m^2 'ye düşen yolcu sayısı 2,86'dan büyük olduğu için Model 14'de optimum sefer sıklığı 12 olarak hesaplanmıştır. 12 sefer sıklığı için hesaplanan m^2 'ye düşen yolcu sayısı 2,85'dir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (12) ESHOT'un belirlediği sefer sıklığından (5) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

193 nolu hat için hafta sonu 17:00-17:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 993 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 63'de gösterilmiştir.

Tablo 63: 193 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	7	13	13	13	11	11
Sefer Başına Yolcu Sayısı	199	142	76	76	76	90	90
Durakta Bekleme Süresi	12,00	8,57	4,62	4,62	4,62	5,45	5,45
Maliyet	192	269	500	500	500	423	423
m^2 'ye Düşen Yolcu Sayısı	5,72	3,96	2,16	2,16	2,16	2,56	2,56
Atıl Kapasite	0	3	857	857	857	572	572
Eksik Kapasite	281,46	0,00	0	0	0	0	0
Atıl zaman Körüklü	6,77	5,08	0,0	0,0	0,0	1,7	1,7
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,23	0,92	0,0	0,0	0,0	0,3	0,3
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Z		11,0	3.797,6	5.528,2	7.028,8	5.231,8	5.231,8

Tablo 63'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de hesaplanan sefer sıklığı 7'dir ve bu değer ESHOT'un uyguladığı sefer sayısından daha yüksektir. Bu durumda maliyet artarken, yolcuların durakta bekleme süreleri ve m^2 'ye düşen yolcu sayısı önemli düzeyde azalmaktadır. ESHOT'un mevcut çizelgesine göre otobüslerin atıl kapasitesi daha yüksek, atıl zamanları daha az olacaktır. Optimum sefer sıklığı Model 6'da ve Model 9'da 13 olarak hesaplanmıştır.

Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de optimum sefer sıklığı 13 olarak hesaplanmıştır. Bu model sapmaları, bekleme süresini, m^2 'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Mevcut çizelgeye göre bu modelde bekleme süresi, m^2 'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13'de optimum sefer sıklığı 11 olarak hesaplanmıştır. 11 sefer sıklığı için hesaplanan m^2 'ye düşen yolcu sayısı 2,86'dan düşük olduğu için model 14'de aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (5) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

193 nolu hat için hafta içi 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 932 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 64'de gösterilmiştir.

Tablo 64: 193 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	7	13	13	13	11	11
Sefer Başına Yolcu Sayısı	186	133	72	72	72	85	85
Durakta Bekleme Süresi	12,00	8,57	4,62	4,62	4,62	5,45	5,45
Maliyet	192	269	500	500	500	423	423
m^2 'ye Düşen Yolcu Sayısı	5,34	3,71	2,02	2,02	2,02	2,39	2,39
Atıl Kapasite	0	64	918	918	918	633	633
Eksik Kapasite	220,46	0,00	0	0	0	0	0
Atıl zaman Körüklü	6,77	5,08	0,0	0,0	0,0	1,7	1,7
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,23	0,92	0,0	0,0	0,0	0,3	0,3
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		11,0	3.870,8	5.486,5	6.987,2	5.305,0	5.305,0

Tablo 64'teki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de hesaplanan sefer sıklığı 7'dir ve bu değer ESHOT'un uyguladığı sefer sayısından fazladır. Optimum sefer sıklığı Model 6'da ve Model 9'da 13 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de optimum sefer sıklığı olan 13 olarak hesaplanmıştır. Bu değer sapmaları, bekleme süresini, m^2 'ye düşen yolcu sayısını ve

maliyeti minimize etmeye çalışmaktadır. Mevcut çizelgeye göre bu modelde bekleme süresi, m^2 'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13'te optimum sefer sıklığı 11 olarak hesaplanmıştır. Bu modelde hesaplanan m^2 'ye düşen yolcu sayısı 2,86'dan düşük olduğu için model 14'de de aynı sonuç elde edilmiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (5) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

193 nolu hat için hafta içi 17:00-17:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 797 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 65'te gösterilmiştir.

Tablo 65: 193 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	6	13	13	13	11	11
Sefer Başına Yolcu Sayısı	159	133	61	61	61	72	72
Durakta Bekleme Süresi	12,00	10,00	4,62	4,62	4,62	5,45	5,45
Maliyet	192	231	500	500	500	423	423
m^2 'ye Düşen Yolcu Sayısı	4,60	3,75	1,71	1,71	1,71	2,05	2,05
Atıl Kapasite	0	57	1053	1053	1053	768	768
Eksik Kapasite	85,46	0,00	0	0	0	0	0
Atıl zaman Körüklü	6,77	5,92	0,0	0,0	0,0	1,7	1,7
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	1,23	1,08	0,0	0,0	0,0	0,3	0,3
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		76,6	4.032,8	5.398,0	6.898,7	5.467,0	5.467,0

Tablo 65'teki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de hesaplanan sefer sıklığı 6'dır ve bu değer ESHOT'un uyguladığı sefer sayısından daha yüksektir. Bu durumda maliyet artarken, yolcuların durakta bekleme süreleri ve m^2 'ye düşen yolcu sayısı önemli düzeyde azalmaktadır. ESHOT'un mevcut çizelgesine göre otobüslerin atıl kapasitesi daha yüksek, atıl zamanları daha az olacaktır. Optimum sefer sıklığı Model 6'da ve Model 9'da 13 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de optimum sefer sıklığı 13 olarak hesaplanmıştır. Bu model sapmaları, bekleme süresini, m^2 'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Mevcut çizelgeye göre bu modelde bekleme süresi,

m²'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13'de optimum sefer sıklığı 11 olarak hesaplanmıştır. Hesaplanan m²'ye düşen yolcu sayısı 2,86'dan düşük olduğu için model 14'de de aynı sonuç elde edilmiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (5) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

ESHOT'un mevcut çizelgesi ve hesaplanan optimum sefer sıklığına göre düzenlenen çizelgeler Tablo 66'da gösterilmiştir. Hem gidiş hem de dönüş yönündeki sefer sıklığı aynı sayıdadır.

Tablo 66: ESHOT'un 193 Nolu Narlıdere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge

Hafta İçi				Hafta Sonu			
Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş İçin Önerilen Çizelge	Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş İçin Önerilen Çizelge
07:01	07:01	17:07	17:07	07:01	07:01	17:07	17:07
07:13	07:06	17:18	17:12	07:13	07:06	17:18	17:12
07:25	07:11	17:29	17:17	07:25	07:12	17:29	17:17
07:38	07:16	17:40	17:21	07:38	07:17	17:40	17:21
07:50	07:21	17:51	17:26	07:50	07:22	17:51	17:26
	07:26		17:31		07:28		17:31
	07:31		17:36		07:33		17:36
	07:35		17:41		07:39		17:41
	07:40		17:46		07:44		17:46
	07:45		17:50		07:49		17:50
	07:50		17:55		07:55		17:55
	07:55						

18 nolu Yeşilyurt – Konak hattı için hafta sonu 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 351 yolcudur. Maliyetler hesaba katılırken 8,6 km mesafedeki yakıt tüketimi hesaplanıp mazot fiyatıyla çarpılmış (6 ₺) bir seferin maliyeti 27,35 ₺ olarak hesaplanmıştır. Hatta 7 körüklü, 4 solo otobüs hizmet vermektedir. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 67'de gösterilmiştir.

Tablo 67: 18 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	3	11	11	11	11	11
Sefer Başına Yolcu Sayısı	70	117	32	32	32	32	32
Durakta Bekleme Süresi	12,00	20,00	5,45	5,45	5,45	5,45	5,45
Maliyet	137	82	301	301	301	301	301
m ² 'ye Düşen Yolcu Sayısı	2,21	3,58	1,00	1,00	1,00	1,00	1,00
Atıl Kapasite	308	44	1099	1099	1099	1099	1099
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	3,82	5,09	0,0	0,0	0,0	0,0	0,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	2,18	2,91	0,0	0,0	0,0	0,0	0,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		76,6	4.591,5	5.390,9	6.293,4	5.494,0	5.494,0

Tablo 67'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 3'tür. ESHOT'un mevcut çizelgesinde sefer sıklığını 5 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da ve Model 9'da 11 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de optimum sefer sıklığı olan 11 olarak hesaplanmıştır. Bu model sapmaları, bekleme süresini, m²'ye düşen yolcu sayısını ve maliyeti minimize etmeye çalışmaktadır. Mevcut çizelgeye göre bu modelde bekleme süresi, m²'ye düşen yolcu sayısı ve atıl zaman daha düşük, maliyet ve atıl kapasite daha fazladır. Model 13'te optimum sefer sıklığı 11 olarak hesaplanmıştır. Hesaplanan m²'ye düşen yolcu sayısı 2,86'dan düşük olduğundan model 14'de aynı sonucu vermiştir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (5) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

18 nolu hat için hafta sonu 18:00-18:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 316 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 68'de gösterilmiştir.

Tablo 68: 18 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	3	11	11	11	11	11
Sefer Başına Yolcu Sayısı	63	105	29	29	29	29	29
Durakta Bekleme Süresi	12,00	20,00	5,45	5,45	5,45	5,45	5,45
Maliyet	137	82	301	301	301	301	301
m ² 'ye Düşen Yolcu Sayısı	1,99	3,22	0,87	0,87	0,87	0,87	0,87
Atıl Kapasite	343	79	1134	1134	1134	1134	1134
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	3,82	5,09	0,0	0,0	0,0	0,0	0,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	2,18	2,91	0,0	0,0	0,0	0,0	0,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		104,9	4.633,5	5.327,3	6.229,7	5.536,0	5.536,0

Tablo 68'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 3'tür. ESHOT'un mevcut çizelgesinde sefer sıklığını 5 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da ve Model 9'da 11 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de optimum sefer sıklığı 11 olarak hesaplanmıştır. Model 13'de ve model 14'de de optimum sefer sıklığı 11 olarak hesaplanmıştır. Körüklü veya solo otobüs sayısı daha fazla olsaydı muhtemelen model 9 11'den daha fazla bir sefer sıklığı hesaplayabilirdi. Bu hatta otobüs sayısının sınırlı olması 5 modelin (6, 9, 12, 13 ve 14. modeller) aynı sonucu vermesini sağlamıştır. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (5) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

18 nolu hat için hafta içi 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 276 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 69'da gösterilmiştir.

Tablo 69: 18 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	3	11	11	11	11	11
Sefer Başına Yolcu Sayısı	55	92	25	25	25	25	25
Durakta Bekleme Süresi	12,00	20,00	5,45	5,45	5,45	5,45	5,45
Maliyet	137	82	301	301	301	301	301
m ² 'ye Düşen Yolcu Sayısı	1,74	2,82	0,78	0,78	0,78	0,78	0,78
Atıl Kapasite	383	119	1174	1174	1174	1174	1174
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	3,82	5,09	0,0	0,0	0,0	0,0	0,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	2,18	2,91	0,0	0,0	0,0	0,0	0,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		152,9	4.681,5	5.301,8	6.204,2	5.584,0	5.584,0

Tablo 69'daki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 3'tür. ESHOT'un mevcut çizelgesinde sefer sıklığını 5 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da ve Model 9'da 11 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de optimum sefer sıklığı 11 olarak hesaplanmıştır. Model 13'de ve model 14'de de optimum sefer sıklığı 11 olarak hesaplanmıştır. Körüklü veya solo otobüs sayısı daha fazla olsaydı muhtemelen model 9 11'den daha fazla bir sefer sıklığı hesaplayabilirdi. Bu hatta otobüs sayısının sınırlı olması 5 modelin (6, 9, 12, 13 ve 14. modeller) aynı sonucu vermesini sağlamıştır. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (5) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

18 nolu hat için hafta içi 18:00-18:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 324 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 70'de gösterilmiştir.

Tablo 70: 18 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	5	3	11	11	11	11	11
Sefer Başına Yolcu Sayısı	65	108	29	29	29	29	29
Durakta Bekleme Süresi	12,00	20,00	5,45	5,45	5,45	5,45	5,45
Maliyet	137	82	301	301	301	301	301
m ² 'ye Düşen Yolcu Sayısı	2,05	3,31	0,93	0,93	0,93	0,93	0,93
Atıl Kapasite	335	71	1126	1126	1126	1126	1126
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	3,82	5,09	0,0	0,0	0,0	0,0	0,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	2,18	2,91	0,0	0,0	0,0	0,0	0,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		95,3	4.623,9	5.370,5	6.273,0	5.526,4	5.526,4

Tablo 70'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de sadece atıl kapasite ve atıl zaman dikkate alındığı için hesaplanan sefer sıklığı 3'tür. ESHOT'un mevcut çizelgesinde sefer sıklığını 5 olarak belirlemiş olması sadece verimlilik ve maliyeti değil aynı zamanda yolcu memnuniyetini de dikkate aldıklarını göstermektedir. Optimum sefer sıklığı Model 6'da ve Model 9'da 11 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de optimum sefer sıklığı 11 olarak hesaplanmıştır. Model 13'de ve model 14'de de optimum sefer sıklığı 11 olarak hesaplanmıştır. Körüklü veya solo otobüs sayısı daha fazla olsaydı muhtemelen model 9 11'den daha fazla bir sefer sıklığı hesaplayabilirdi. Bu hatta otobüs sayısının sınırlı olması 5 modelin (6, 9, 12, 13 ve 14. modeller) aynı sonucu vermesini sağlamıştır. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (5) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

ESHOT'un mevcut çizelgesi ve hesaplanan optimum sefer sıklığına göre düzenlenen çizelgeler Tablo 71'de gösterilmiştir. Hem gidiş hem de dönüş yönündeki sefer sıklığı aynı sayıdadır.

Tablo 71: ESHOT'un 18 Nolu Narlıdere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge

Hafta İçi				Hafta Sonu			
Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş İçin Önerilen Çizelge	Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş İçin Önerilen Çizelge
07:06	07:06	18:04	18:04	07:06	07:06	18:04	18:04
07:17	07:11	18:16	18:09	07:17	07:11	18:16	18:09
07:29	07:16	18:28	18:14	07:29	07:16	18:28	18:14
07:40	07:21	18:40	18:19	07:40	07:21	18:40	18:19
07:51	07:26	18:50	18:24	07:51	07:26	18:50	18:24
	07:31		18:29		07:31		18:29
	07:35		18:35		07:35		18:35
	07:40		18:40		07:40		18:40
	07:45		18:45		07:45		18:45
	07:50		18:50		07:50		18:50
	07:55		18:55		07:55		18:55

465 nolu Tınaztepe – Konak hattı için hafta sonu 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 1.156 yolcudur. Maliyetler hesaba katılırken 10,2 km mesafedeki yakıt tüketimi hesaplanıp mazot fiyatıyla çarpılmış (6 ₺) bir seferin maliyeti 32,44 ₺ olarak hesaplanmıştır. Hatta 10 körüklü, 1 solo otobüs hizmet vermektedir. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 72’de gösterilmiştir.

Tablo 72: 465 Nolu Hattın Hafta Sonu Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	6	8	11	11	11	11	11
Sefer Başına Yolcu Sayısı	193	145	105	105	105	105	105
Durakta Bekleme Süresi	10,00	7,50	5,45	5,45	5,45	5,45	5,45
Maliyet	195	259	357	357	357	357	357
m ² 'ye Düşen Yolcu Sayısı	5,45	3,98	2,88	2,88	2,88	2,88	2,88
Atıl Kapasite	0	8	444	444	444	444	444
Eksik Kapasite	283,27	0,00	0	0	0	0	0
Atıl zaman Körüklü	4,55	2,73	0,0	0,0	0,0	0,0	0,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,45	0,27	0,0	0,0	0,0	0,0	0,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		12,8	3.805,5	6.113,3	7.183,7	4.875,9	-1,0

Tablo 72’deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3’de hesaplanan sefer sıklığı 8’dir ve bu değer ESHOT’un uyguladığı sefer sayısından daha yüksektir. Bu durumda maliyet ve atıl kapasite artarken, yolcuların durakta

bekleme süreleri, m^2 'ye düşen yolcu sayısı ve otobüslerin atıl zamanları azalmaktadır. Optimum sefer sıklığı Model 6'da ve Model 9'da 11 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de optimum sefer sıklığı 11 olarak hesaplanmıştır. Model 13'de ve model 14'de de optimum sefer sıklığı 11 olarak hesaplanmıştır. Körüklü veya solo otobüs sayısı daha fazla olsaydı muhtemelen model 9 11'den daha fazla bir sefer sıklığı hesaplayabilirdi. Bu hatta otobüs sayısının sınırlı olması 5 modelin (6, 9, 12 ve 13. modeller) aynı sonucu vermesini sağlamıştır. Model 14'te sistem kısıtının sağlanabilmesi için sefer sıklığının 12 olması gereklidir. Ancak Tablo 72'de z değerinin “-1” olması otobüs sayısının yetersiz olması nedeniyle olurlu çözüm olmadığını göstermektedir. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (6) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

465 nolu hat için hafta sonu 19:00-19:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 676 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 73'de gösterilmiştir.

Tablo 73: 465 Nolu Hattın Hafta Sonu Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	3	5	11	11	11	11	11
Sefer Başına Yolcu Sayısı	225	135	61	61	61	61	61
Durakta Bekleme Süresi	20,00	12,00	5,45	5,45	5,45	5,45	5,45
Maliyet	97	162	357	357	357	357	357
m^2 'ye Düşen Yolcu Sayısı	5,82	3,49	1,69	1,69	1,69	1,69	1,69
Atıl Kapasite	0	51	924	924	924	924	924
Eksik Kapasite	239,64	0,00	0	0	0	0	0
Atıl zaman Körüklü	7,27	5,45	0,0	0,0	0,0	0,0	0,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,73	0,55	0,0	0,0	0,0	0,0	0,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		68,7	4.381,5	5.733,1	6.803,5	5.451,9	5.451,9

Tablo 73'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de hesaplanan sefer sıklığı 5'dir ve bu değer ESHOT'un uyguladığı sefer sayısından daha yüksektir. Bu durumda maliyet ve atıl kapasite artarken, yolcuların durakta

bekleme süreleri, m^2 'ye düşen yolcu sayısı ve otobüslerin atıl zamanları azalmaktadır. Optimum sefer sıklığı Model 6'da ve Model 9'da 11 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de, model 13'de ve model 14'de de optimum sefer sıklığı 11 olarak hesaplanmıştır. Körüklü veya solo otobüs sayısı daha fazla olsaydı muhtemelen model 9 11'den daha fazla bir sefer sıklığı hesaplayabilirdi. Bu hatta otobüs sayısının sınırlı olması 5 modelin (6, 9, 12, 13 ve 14. modeller) aynı sonucu vermesini sağlamıştır. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (3) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

465 nolu hat için hafta içi 07:00-07:59 zaman aralığı için tahmin edilen maksimum hat talebi gidiş yönünde 854 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 74'te gösterilmiştir.

Tablo 74: 465 Nolu Hattın Hafta İçi Gidiş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	6	6	11	11	11	11	11
Sefer Başına Yolcu Sayısı	142	142	78	78	78	78	78
Durakta Bekleme Süresi	10,00	10,00	5,45	5,45	5,45	5,45	5,45
Maliyet	195	195	357	357	357	357	357
m^2 'ye Düşen Yolcu Sayısı	4,04	4,04	2,12	2,12	2,12	2,12	2,12
Atıl Kapasite	19	19	746	746	746	746	746
Eksik Kapasite	0,00	0,00	0	0	0	0	0
Atıl zaman Körüklü	4,55	4,55	0,0	0,0	0,0	0,0	0,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,45	0,45	0,0	0,0	0,0	0,0	0,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		68,7	4.167,9	5.862,0	6.932,4	5.238,3	5.238,3

Tablo 74'deki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de hesaplanan sefer sıklığı 6'dır ve bu değer ESHOT'un uyguladığı sefer sayısına eşittir. Optimum sefer sıklığı Model 6'da ve Model 9'da 11 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m^2 'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de, model 13'de ve model 14'de de optimum sefer sıklığı 11 olarak hesaplanmıştır. Körüklü veya solo otobüs sayısı daha fazla olsaydı

muhtemelen model 9 11'den daha fazla bir sefer sıklığı hesaplayabilirdi. Bu hatta otobüs sayısının sınırlı olması 5 modelin (6, 9, 12, 13 ve 14. modeller) aynı sonucu vermesini sağlamıştır. Model 14 işletmenin en düşük maliyetle en yüksek yolcu memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (6) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

465 nolu hat için hafta içi 19:00-19:59 zaman aralığı için tahmin edilen maksimum hat talebi dönüş yönünde 614 yolcudur. Bu talep düzeyi için sefer sıklığı optimizasyon modellerinden elde edilen sonuçlar Tablo 75'te gösterilmiştir.

Tablo 75: 465 Nolu Hattın Hafta İçi Dönüş Yönü için Sefer Sıklığı Optimizasyon Modellerinin Sonuçları

	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	3	5	11	11	11	11	11
Sefer Başına Yolcu Sayısı	205	123	56	56	56	56	56
Durakta Bekleme Süresi	20,00	12,00	5,45	5,45	5,45	5,45	5,45
Maliyet	97	162	357	357	357	357	357
m ² 'ye Düşen Yolcu Sayısı	5,30	3,18	1,52	1,52	1,52	1,52	1,52
Atıl Kapasite	0	113	986	986	986	986	986
Eksik Kapasite	177,64	0,00	0	0	0	0	0
Atıl zaman Körüklü	7,27	5,45	0,0	0,0	0,0	0,0	0,0
Eksik Zaman Körüklü	0,00	0,00	0,0	0,0	0,0	0,0	0,0
Atıl zaman Solo	0,73	0,55	0,0	0,0	0,0	0,0	0,0
Eksik zaman Solo	0,00	0,00	0,0	0,0	0,0	0,0	0,0
z		143,1	4.455,9	5.671,9	6.742,3	5.526,3	5.526,3

Tablo 75'teki hiçbir modelde eksik kapasite veya eksik zaman yoktur. Model 3'de hesaplanan sefer sıklığı 5'tir ve bu değer ESHOT'un uyguladığı sefer sayısından daha yüksektir. Bu durumda maliyet ve atıl kapasite artarken, yolcuların durakta bekleme süreleri, m²'ye düşen yolcu sayısı ve otobüslerin atıl zamanları azalmaktadır. Optimum sefer sıklığı Model 6'da ve Model 9'da 11 olarak hesaplanmıştır. Model 6'da bekleme süresinin, model 9'da hem bekleme süresinin hem de m²'ye düşen yolcu sayısı değişkenlerinin hesaba katılması nedeniyle daha yüksek bir sefer sıklığı hesaplanmıştır. Model 12'de, model 13'de ve model 14'de de optimum sefer sıklığı 11 olarak hesaplanmıştır. Körüklü veya solo otobüs sayısı daha fazla olsaydı muhtemelen model 9 11'den daha fazla bir sefer sıklığı hesaplayabilirdi. Bu hatta otobüs sayısının sınırlı olması 5 modelin (6, 9, 12, 13 ve 14. modeller) aynı sonucu vermesini sağlamıştır. Model 14 işletmenin en düşük maliyetle en yüksek yolcu

memnuniyetini sağlamayı hedeflemektedir. Buna karşın hesaplanan sefer sıklığı (11) ESHOT'un belirlediği sefer sıklığından (3) yüksek olmuştur. Bu çizelge uygulanırsa maliyet ve atıl kapasite artacaktır ama yolcuların memnuniyeti daha yüksek düzeyde olacaktır.

ESHOT'un mevcut çizelgesi ve hesaplanan optimum sefer sıklığına göre düzenlenen çizelgeler Tablo 76'da gösterilmiştir. Hem gidiş hem de dönüş yönündeki sefer sıklığı aynı sayıdadır.

Tablo 76: ESHOT'un 465 Nolu Narlıdere – Konak Hattı için Uyguladığı Çizelge ile Algoritma Sonucunda Elde Edilen Çizelge

Hafta İçi				Hafta Sonu			
Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş için önerilen Çizelge	Mevcut Gidiş Çizelgesi	Gidiş İçin Önerilen Çizelge	Mevcut Dönüş Çizelgesi	Dönüş için önerilen Çizelge
07:00	07:00	19:10	19:10	07:00	07:00	19:10	19:10
07:10	07:05	19:30	19:15	07:10	07:05	19:30	19:15
07:20	07:11	19:55	19:19	07:20	07:11	19:55	19:19
07:30	07:16		19:24	07:30	07:16		19:24
07:40	07:22		19:28	07:40	07:22		19:28
07:50	07:27		19:33	07:50	07:27		19:33
	07:33		19:37		07:33		19:37
	07:38		19:42		07:38		19:42
	07:44		19:46		07:44		19:46
	07:49		19:51		07:49		19:51
	07:55		19:55		07:55		19:55


4.12.5. Tahmini Talep ve Hat Parametreleri Kullanılarak Optimum Sefer Sıklıklarının Genetik Algoritma ile Belirlenmesi

Önceki başlıkta ele alınan hedef programlama tabanlı matematiksel modellerin amaç denklem olarak kullanıldığı ve uygunluk fonksiyonuna dönüştürüldüğü bir genetik algoritma geliştirilmiştir. Bu çalışmada 10 hat için sefer sıklığı optimizasyonu yapılmıştır ve bu problem np-zor sınıfında değildir. Ancak incelenen hat sayısı arttıkça problem zorlaşacak ve np-zor sınıfı bir problem haline gelecektir. Np-zor sınıfı problemleri çözmek için hedef programlama algoritmaları ile çözüm bulmak zor veya imkansız olacaktır. Bu noktada genetik algoritma modeli ile optimal çözümler elde etmek mümkün olabilir. Bu nedenle genetik algoritma kullanımına karar verilmiştir. Bu genetik algoritmada tamsayı kodlama yapılmıştır. Her birey her hattın hafta içi ve hafta sonu gidiş ve dönüş yönlerine ilişkin sefer bilgilerini taşıyan toplam 40 genden

oluşmaktadır. Her gen o hatta ilişkin temel parametreleri (km cinsinden hat uzunluğu, ortalama sefer süresi, hatta kullanılan körüklü ve solo otobüs sayısı ve ysa'dan elde edilen tahmini talep düzeyi) ve sefer sıklığı bilgilerini taşımaktadır. Genetik algoritmanın yapısal detayı prototip uygulama başlığı altında verilmiştir.

Tek noktalı çaprazlama, tek noktalı veya çok noktalı probleme özel mutasyon operatörleri, rulet tekerleği seçimi ve elitizm operatörü kullanılan bu genetik algoritmanın temel parametreleri model 3 için optimize edilmiştir. Öncelikle popülasyon büyüklüğünün elde edilen sonuca etkisi her büyüklük için 10 deney yapılarak uygunluk değerlerinin ortalamaları incelenmiş ve Şekil 71'de gösterilmiştir. Deneylerde çaprazlama oranı 0,7, mutasyon oranı 0,1 olarak seçilmiş ve sabit tutulmuştur.

Şekil 71: Genetik Algoritma Popülasyon Büyüklüğünün Algoritma Uygunluk Değerine Etkisi




Şekil 71'de başlangıçta popülasyon büyüklüğü arttıkça uygunluk değerinde hızlı bir düşüş gözlenirken, popülasyon büyüklüğü 10'u geçtiğinde uygunluk değerlerinin yatay bir trend izlediği görülmektedir. Bu nedenle algoritmada popülasyon büyüklüğü 10 olarak belirlenmiştir.

Genetik algoritma performansı üzerinde önemli etkisi olan bir diğer parametre çaprazlama oranıdır. Yeni nesil üretilirken ne oranda bireye çaprazlama uygulanacağını belirleyen bir değerdir. Literatürde farklı oranların iyi sonuç verebileceğine vurgu yapılırsa da genellikle problemden probleme en iyi çaprazlama oranının farklılık gösterdiği vurgulanmaktadır. Bu nedenle popülasyon büyüklüğü gibi çaprazlama oranı da 10 deneyde elde edilen ortalama uygunluk değerlerine göre

incelenmiştir. Bu 10 deneyde popülasyon büyüklüğü 10 ve mutasyon oranı 0,1 olarak seçilmiş ve sabit tutulmuştur. Deneylerde elde edilen sonuçlar Şekil 72’de gösterilmiştir.


Şekil 72’de çaprazlama oranı arttıkça uygunluk değerinin başlangıçta hızlı düştüğü, 0,7’den sonra ise yatay trend izlediği görülmektedir. Bu nedenle algoritma optimum sefer sıklıklarını hesaplarken çaprazlama oranı 0,7 olarak kullanılmıştır.

Şekil 72: Çaprazlama Oranının Genetik Algoritma Uygunluk Değerine Etkisi




Genetik algoritmanın performansında mutasyon oranı da son derece etkilidir. Bu değerin de deneysel çalışma ile belirlenmesi faydalıdır. Optimum mutasyon oranını belirlemek üzere 10 adet deney yapılarak ortalama uygunluk değerleri incelenmiş ve Şekil 73’de gösterilmiştir.

Şekil 73: Mutasyon Oranının Genetik Algoritma Uygunluk Değerine Etkisi



Şekil 73’de mutasyon oranı arttıkça uygunluk değerlerinde başlangıçta hızlı bir düşüş gerçekleşirken 0,1 değerinden sonra yatay trend izlemiştir. Bu nedenle mutasyon oranının 0,1 olarak belirlenmesi uygun görülmüştür. Mutasyon operatörünün nokta sayısı da uygunluk değeri üzerinde etkili olabilir. Bu nedenle bireylerin kaç geninde mutasyon uygulanması gerektiği de 10 deney yapılarak anlaşılmasına çalışılmıştır. Yapılan deneylerde popülasyon büyüklüğü 10, çaprazlama oranı 0,7 ve mutasyon oranı 0,1 olarak sabit tutulmuştur. Mutasyona uğrayan gen sayısı 1-15 arasında değiştirilerek algorithmadan elde edilen uygunluk değerlerinin ortalaması incelenmiş ve Şekil 74’de gösterilmiştir.

Şekil 74: Bireyde Mutasyona Uğrayan Gen Sayısının Genetik Algoritma Uygunluk Değerine Etkisi



Şekil 74’de bireylerin 5 geninde mutasyon uygulanınca en iyi sonuca ulaşıldığı. Mutasyona uğrayacak gen sayısını arttırmanın uygunluk değerlerinde bir iyileşme sağlamadığı ve hatta 9’un üstünde gene mutasyon uygulanınca uygunluk değerlerinin azaldığı görülmektedir. Bunun nedeni bireylerin genetik yapısının aşırı bozulması nedeniyle algoritmanın rastgele arama algoritmasına dönüşmesidir.

Genetik algoritmanın parametreleri belirlendikten sonra 500 nesil üretecek şekilde çalıştırılmıştır. Bu işlem 1 dakika 34 sn gibi kısa bir sürede tamamlanmaktadır ve optimum sonucu vermektedir. Genetik operatörlerin problemin özelliklerine göre uygun gen değişikliklerini yapması bu kadar kısa sürede optimum çözüm üretmesini sağlamaktadır. Önerilen algoritma, genetik algorithmada elde edilen sonuçlar model 3 için Tablo 77’de, model 6 için Tablo 78’de, model 9 için Tablo 79’da, model 12 için Tablo 80’de, model 13 için Tablo 81’de ve model 14 için Tablo 82’de gösterilmiştir. Vuchic’in bağıntısından elde edilen sonuçlar Tablo 83’de gösterilmiştir. Bağıntıdaki

α_i değeri, otobüslerin en fazla kapasiteye kadar yüklenebileceği öngörüldüğünden “1” olarak alınmıştır. Kullanılan araçlar körüklü ve solo otobüsler olduğundan n_i değeri de “1” olarak alınmıştır.

Tablo 77: Model 3 için Önerilen Basit Algoritma ve Genetik Algoritma Sonuçları

Yöntem	Hat	Hafta Sonu Gidiş	Hafta Sonu Dönüş	Hafta İçi Gidiş	Hafta İçi Dönüş
Basit Yöntem	63	8	8	7	6
	802	4	3	4	3
	171	8	4	6	3
	554	5	3	6	3
	169	3	2	3	2
	23	8	6	6	5
	285	8	5	6	5
	193	9	7	7	6
	18	3	3	3	3
	465	8	5	6	5
Genetik Algoritma	63	8	8	7	6
	802	4	3	4	3
	171	8	4	6	3
	554	5	3	6	3
	169	3	2	3	2
	23	8	6	6	5
	285	8	5	6	5
	193	9	7	7	6
	18	3	3	3	3
	465	8	5	6	5

Tablo 78: Model 6 için Önerilen Basit Algoritma ve Genetik Algoritma Sonuçları

Yöntem	Hat	Hafta Sonu Gidiş	Hafta Sonu Dönüş	Hafta İçi Gidiş	Hafta İçi Dönüş
Basit Yöntem	63	14	14	14	14
	802	15	15	15	15
	171	15	15	15	15
	554	13	13	13	13
	169	13	13	13	13
	23	15	15	15	15
	285	12	12	12	12
	193	13	13	13	13
	18	11	11	11	11
	465	11	11	11	11
Genetik Algoritma	63	14	14	14	14
	802	15	15	15	15
	171	15	15	15	15
	554	13	13	13	13
	169	13	13	13	13
	23	15	15	15	15
	285	12	12	12	12
	193	13	13	13	13
	18	11	11	11	11
	465	11	11	11	11

Tablo 79: Model 9 için Önerilen Basit Algoritma ve Genetik Algoritma Sonuçları

Yöntem	Hat	Hafta Sonu Gidiş	Hafta Sonu Dönüş	Hafta İçi Gidiş	Hafta İçi Dönüş
Basit Yöntem	63	18	18	17	19
	802	17	17	17	15
	171	18	17	18	16
	554	13	13	13	13
	169	13	13	13	13
	23	18	18	18	18
	285	12	12	12	12
	193	13	13	13	13
	18	11	11	11	11
	465	11	11	11	11
	465	11	11	11	11
Genetik Algoritma	63	18	18	17	19
	802	17	17	17	15
	171	18	17	18	16
	554	13	13	13	13
	169	13	13	13	13
	23	18	18	18	18
	285	12	12	12	12
	193	13	13	13	13
	18	11	11	11	11
	465	11	11	11	11
	465	11	11	11	11

Tablo 80: Model 12 için Önerilen Basit Algoritma ve Genetik Algoritma Sonuçları

Yöntem	Hat	Hafta Sonu Gidiş	Hafta Sonu Dönüş	Hafta İçi Gidiş	Hafta İçi Dönüş
Basit Yöntem	63	15	14	13	14
	802	11	11	11	10
	171	11	11	11	11
	554	11	11	12	10
	169	12	12	12	12
	23	15	15	15	14
	285	12	12	12	12
	193	13	13	13	13
	18	11	11	11	11
	465	11	11	11	11
Genetik Algoritma	63	15	14	13	14
	802	11	11	11	10
	171	11	11	11	11
	554	11	11	12	10
	169	12	12	12	12
	23	15	15	15	14
	285	12	12	12	12
	193	13	13	13	13
	18	11	11	11	11
	465	11	11	11	11

Tablo 81: Model 13 için Önerilen Basit Algoritma ve Genetik Algoritma Sonuçları

Yöntem	Hat	Hafta Sonu Gidiş	Hafta Sonu Dönüş	Hafta İçi Gidiş	Hafta İçi Dönüş
Basit Yöntem	63	11	11	11	11
	802	10	10	10	10
	171	10	10	10	10
	554	9	9	9	9
	169	11	11	11	11
	23	12	12	12	12
	285	11	11	11	11
	193	11	11	11	11
	18	11	11	11	11
	465	11	11	11	11
Genetik Algoritma	63	11	11	11	11
	802	10	10	10	10
	171	10	10	10	10
	554	9	9	9	9
	169	11	11	11	11
	23	12	12	12	12
	285	11	11	11	11
	193	11	11	11	11
	18	11	11	11	11
	465	11	11	11	11

Tablo 82: Model 14 için Önerilen Basit Algoritma ve Genetik Algoritma Sonuçları

Yöntem	Hat	Hafta Sonu Gidiş	Hafta Sonu Dönüş	Hafta İçi Gidiş	Hafta İçi Dönüş
Basit Yöntem	63	11	11	11	11
	802	10	10	10	10
	171	11	10	10	10
	554	9	9	9	9
	169	11	11	11	11
	23	12	12	12	12
	285	11	11	11	11
	193	12	11	11	11
	18	11	11	11	11
	465	11	11	11	11
Genetik Algoritma	63	11	11	11	11
	802	10	10	10	10
	171	11	10	10	10
	554	9	9	9	9
	169	11	11	11	11
	23	12	12	12	12
	285	11	11	11	11
	193	12	11	11	11
	18	11	11	11	11
	465	11	11	11	11

Tablo 83: Vuchic'in Bağıntısından Elde Edilen Sonuçlar

Hat	Hafta Sonu Gidiş	Hafta Sonu Dönüş	Hafta İçi Gidiş	Hafta İçi Dönüş
63	10	8	8	6
802	8	8	7	7
171	13	6	9	5
554	6	3	5	3
169	5	3	4	3
23	5	4	4	4
285	5	3	4	3
193	5	6	4	4
18	2	4	3	4
465	6	4	5	4

Tablo 77, 78, 79, 80, 81 ve 82’de genetik algoritmanın basit algoritma kadar kısa sürede olmasa da optimum sonuç verdiği görülmektedir. Tablolarda ele alınan hatlar için hafta sonu ve hafta içi günleri gidiş ve dönüş yönleri için hesaplanan optimum sefer sıklıkları gösterilmiştir. Model 3’te elde edilen sonuçların Vuchic’in bağıntısına göre genellikle daha düşük sefer sıklıkları hesapladığı görülmüştür. Model6, Model 9, Model 12, Model 13 ve Model 14 ile elde edilen sonuçların Vuchic’in bağıntısı ile elde edilen sonuçlardan daha yüksek olduğu görülmektedir. Bunun nedeni Vuchic’in bağıntısının mevcut kapasite ile talebi karşılayan bir sefer sıklığı hesaplamasıdır. Yani bu bağıntıda yolcuların durakta bekleme süreleri ve otobüste kişi başına düşen alan gibi hizmet kalitesine ilişkin parametreler dikkate alınmamaktadır.

4.12.6. Modellerin Toplu Değerlendirilmesi

Esas uygulamada kullanılan 6 model ve ESHOT’un uyguladığı çizelgelerin toplu sonuçları Tablo 84’de gösterilmiştir. Atıl kapasite sütununda görülen pozitif değerler atıl kapasiteyi, negatif değerler ise eksik kapasiteyi göstermektedir.

Tablo 84: Optimizasyon Modellerinin Toplu Sonuçları

	Hat No	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	63	9	8	14	18	15	11	11
Durakta Bekleme Süresi		6,67	7,5	4,29	3,33	4	5,45	5,45
Maliyet		381	338	592	761	634	465	465
m ² 'ye Düşen Yolcu Sayısı		3,18	3,6	2,16	1,62	1,99	2,74	2,74
Atıl Kapasite		218	70	955	1.545	1.103	513	513
Sefer Sıklığı	802	11	4	15	17	11	10	10
Durakta Bekleme Süresi		5,45	15	4	3,53	5,45	6	6
Maliyet		819	298	1.116	1.265	819	744	744
m ² 'ye Düşen Yolcu Sayısı		1,39	3,62	1,03	0,91	1,39	1,53	1,53
Atıl Kapasite		1.020	14	1.595	1.883	1.020	877	877
Sefer Sıklığı	171	12	8	15	18	11	10	11
Durakta Bekleme Süresi		5	7,5	4	3,33	5,45	6	5,45
Maliyet		767	511	959	1.151	703	639	703
m ² 'ye Düşen Yolcu Sayısı		2,69	3,96	2,11	1,73	2,79	3,11	2,79
Atıl Kapasite		579	6	1.009	1.438	436	293	436
Sefer Sıklığı	554	4	5	13	13	11	9	9
Durakta Bekleme Süresi		15	12	4,62	4,62	5,45	6,67	6,67
Maliyet		309	386	1.005	1.005	850	695	695
m ² 'ye Düşen Yolcu Sayısı		4,32	3,47	1,4	1,4	1,66	2,03	2,03
Atıl Kapasite		0	62	1.231	1.231	939	646	646
Sefer Sıklığı	169	5	3	13	13	12	11	11
Durakta Bekleme Süresi		12	20	4,62	4,62	5	5,45	5,45
Maliyet		197	118	513	513	473	434	434
m ² 'ye Düşen Yolcu Sayısı		2,02	3,36	0,78	0,78	0,83	0,91	0,91
Atıl Kapasite		361	61	1.561	1.561	1.411	1.261	1.261

	Hat No	Mevcut Durum	Model 3	Model 6	Model 9	Model 12	Model 13	Model 14
Sefer Sıklığı	23	11	8	15	18	15	12	12
Durakta Bekleme Süresi		5,45	7,5	4	3,33	4	5	5
Maliyet		311	226	425	509	425	340	340
m ² 'ye Düşen Yolcu Sayısı		2,67	3,59	1,91	1,64	1,91	2,42	2,42
Atıl Kapasite		519	94	1.086	1.511	1.086	661	661
Sefer Sıklığı	285	5	8	12	12	12	11	11
Durakta Bekleme Süresi		12	7,5	5	5	5	5,45	5,45
Maliyet		238	380	570	570	570	523	523
m ² 'ye Düşen Yolcu Sayısı		5,66	3,79	2,49	2,49	2,49	2,72	2,72
Atıl Kapasite		-367	71	654	654	654	508	508
Sefer Sıklığı	193	5	9	13	13	13	11	12
Durakta Bekleme Süresi		12	6,67	4,62	4,62	4,62	5,45	5
Maliyet		192	346	500	500	500	423	462
m ² 'ye Düşen Yolcu Sayısı		6,92	3,68	2,61	2,61	2,61	3,13	2,85
Atıl Kapasite		-497	72	641	641	641	356	499
Sefer Sıklığı	18	5	3	11	11	11	11	11
Durakta Bekleme Süresi		12	20	5,45	5,45	5,45	5,45	5,45
Maliyet		137	82	301	301	301	301	301
m ² 'ye Düşen Yolcu Sayısı		2,21	3,58	1	1	1	1	1
Atıl Kapasite		308	44	1.099	1.099	1.099	1.099	1.099
Sefer Sıklığı	465	6	8	11	11	11	11	11
Durakta Bekleme Süresi		10	7,5	5,45	5,45	5,45	5,45	5,45
Maliyet		195	259	357	357	357	357	357
m ² 'ye Düşen Yolcu Sayısı		5,45	3,98	2,88	2,88	2,88	2,88	2,88
Atıl Kapasite		-283	8	444	444	444	444	444

Tablo 84'de bütün hatlar için en düşük sefer sıklığını model 1'in verdiği görülmektedir. Yolcuların durakta bekleme süresi bakımından en iyi sonucu genelde model 9 (10 hatta) vermektedir. Model 9'u 6 hatta en iyi bekleme süresini veren model 6 ve 4 hatta en iyi bekleme süresini veren model 12 takip etmektedir. Maliyete göre en iyi sonucu 10 hatta da düşük sefer sıklığı hesapladığı için model 3 vermektedir. m²'ye düşen yolcu sayısı bakımından en iyi sonucu 10 hatta da model 9 vermektedir. Model 9'u 6 hatta en iyi sonucu veren model 6 ve 4 hatta en iyi sonucu

veren model 12 izlemektedir. Atıl kapasite bakımından en iyi sonucu veren model düşük sefer sıklığı hesapladığı için model 3'tür.

Bu sonuçlara göre yolcuların durakta bekleme süresi ve m^2 'ye düşen yolcu sayısı gibi kalite algısını olumlu etkileyen değişkenleri öne çıkarmak isteyen karar alıcıların model 9'u, maliyeti ve atıl kapasiteyi öne çıkarmak isteyen karar alıcıların model 3'ü kullanması uygun olacaktır. Kalite algısı ile maliyeti ve atıl kapasiteyi dengelemek içinse model 12, model 13 veya model 14'ü kullanması uygun olacaktır. Model 13 ve model 14 çoğunlukla aynı sonuçları vermektedir. Ancak 171 ve 193 nolu hatlarda m^2 'ye düşen yolcu sayısının 2,86'dan küçük olması kısıtı nedeniyle model 14 model 13'ten fazla sefer sayısı hesaplamıştır.

5. SONUÇ

Bir şehirde yollar, kavşaklar, trafik ışıkları, yaya geçitleri, durak, istasyon veya liman gibi ulaşım tesislerinin şehirdeki yerleşim alanları, iş merkezleri, eğlenme, dinlenme, alışveriş merkezi gibi cazibe merkezleri, hastane, okul gibi kamu kurumları dikkate alınarak planlanması, planın uygulamaya konulması, uygulamanın denetlenmesi ve aksaklıkların tespit edilerek düzeltici önlemlerin alınması son derece önemlidir. Şehirdeki ulaşım tesisleri planlanırken yetkili belediyenin nazım imar planlarını, çevreye hava ve gürültü kirliliği bakımından etkilerini, şehir sakinlerinin ulaşım taleplerini dikkate almak gerekir.

Toplu taşıma tesisleri, toplu taşıma araçları ve sefer sıklıkları, aktarma yapma olanakları, yolların ve trafik düzenlemelerinin kentteki insanların yaşam kalitesi üzerinde olumlu veya olumsuz etkileri mevcuttur. Bu nedenle toplu taşıma planlaması, tesislerin kurulması ve işletilmesi yetkisi şehir planlama yetkisini de elinde bulunduran belediyelere verilmiştir. Belediyeler şehirdeki insanların nüfus değişimlerini, demografik özelliklerini, gelir durumlarını, özel araç sahipliklerini, eğitim, sağlık, adalet, güvenlik, sosyal ve çevresel taleplerini dikkate alarak şehir planlamasını gerçekleştirirler. Şehir planlamasını yaparken aynı zamanda ulaşım planlamasını da bu plana uygun olarak gerçekleştirerek halkın memnuniyetini sağlamaya çalışırlar. Bu nedenle her belediyenin ulaştırma yönetimini gerçekleştiren özel birimleri bulunur. Stratejik düzeydeki bu kararlar belediyede bu birimler tarafından ulaşım ana planı olarak hazırlanır ve belediye meclisi ve başkanının onayıyla geçerlilik kazanır.

Şehir planlaması kapsamındaki tesislerin inşası dışında o tesisler üzerinde çalışacak araçların (minibüs, otobüs, metro, gemi vb.) satın alınması, şehirdeki bölgeler arasında hatların oluşturulması, bu araçların ve şoförlerin hatlara görevlendirilmesi, araçların ve tesislerin bakım ve onarımlarının planlanması, araçların sefer sıklıklarının belirlenerek sefer çizelgelerinin oluşturulması gibi taktiksel düzeyde planlamalar da yapılmalıdır. Bu planlama ve işletim faaliyetleri için özellikle büyükşehirlerde belediyeye bağlı işletmeler kurulurlar. İzmir’de ESHOT, İstanbul’da İETT bu kurumlara örnek verilebilir. Bu kuruluşlar uzun vadeli ulaşım ana planına uygun olarak kendi planlarını oluştururlar.

Stratejik düzeyde ulaşım ana planının ve taktiksel düzeyde acil eylem planlarının en önemli ve belirsiz bilgi girdisi talep düzeyidir. Talep düzeyi kesin olarak bilinemeyeceğinden dört aşamalı ulaşım modeli kullanılarak tahmin edilmeye çalışılır. Tahmin edilen talep düzeyine göre bölgelere yeni tesisler kurulması, bazı tesislerin kaldırılması, ulaşım araçlarının satın alınması gibi stratejik veya taktik kararlar alınır ve ilgili planlara yansıtılır.

Ulaşım ana planı oluşturulurken talep tahmini aşamasında hane halkı, yol kenarı, yurt anketleri ve trafik sayımları veri kaynağı olarak kullanılmaktadır. Bu veri kaynakları iyi örnekleme yöntemleri kullanılmasını, toplanan verilerin doğru yöntemlerle analiz edilmesini gerektirmektedir. Bu yöntemler çok uzun zaman alması, çok yüksek maliyetlere neden olması, çok fazla nitelikli işgücü gerektirmesi gibi zorluklara sahiptir. Akıllı kart ve GPS teknolojilerinin toplu taşıma alanında ücret toplamak amacıyla kullanılması ulaşım planlamacıları için yeni bir bilgi kaynağı sağlamıştır. Bu bilgi kaynağı büyük veri analizi ve veri madenciliği yöntemleriyle planlamacılara çok faydalı olma potansiyeli taşımaktadır. 2000’li yıllardan bu yana akıllı kart verilerinden faydalı bilgi elde edebilmek için hem ulaşım planlamacıları hem de bilim insanları çalışmalarını yoğunlaştırmaktadır. Yabancı literatürde bu konularda çok sayıda yayın mevcut iken yerli literatürde çok az sayıda yayın bulunmaktadır.

Bu çalışmada akıllı kart verilerinin bu potansiyelinden faydalanarak başlangıç-varış matrislerini durak düzeyinde hesaplamanın, maksimum hat yüklerini hesaplamanın, elde edilecek bu talep bilgileri ile eğitilen YSA’lar ile gelecek öngörüsü yapmanın, hat parametreleri ve tahmin edilen talep düzeyine göre optimum sefer sıklıklarını hesaplamanın mümkün olduğu gösterilmiştir. Bu çalışmada ESHOT Genel

Müdürlüğü'nün izniyle ilgili birimlerden elde edilen 2015 yılı Mayıs ayının ilk 15 gününe ait akıllı kart verileriyle, 2017 yılı Ekim ayına ait 30 günlük akıllı kart verileri kullanılmıştır. 2015 yılına ait veriler prototip uygulamayı geliştirirken kullanılmış, 2017 verileri ise esas uygulamayı test etmek için kullanılmıştır. Bu verilerdeki en önemli sorun yolcuların sadece binış duraklarının bilinmesi, iniş duraklarına ilişkin bilgi bulunmamasıdır. Bu nedenle literatürde yaygın olarak kullanılan yolculuk zincirleme algoritması ve Diker'in önerdiği rastgele atama tahmin yöntemi ile son durağa atama yöntemleri kullanılarak iniş duraklarını tahminleyen algoritma kodlanmıştır. Yolculuk zincirleme algoritması iniş duraklarının yaklaşık % 60'ını tahmin edebilmiştir. Bu tahminlere göre oluşturulan geçici BV matrisi kullanılarak yolculukların duraklara dağılımına uygun olarak rastgele atama yapan Diker'in rastgele atama yöntemi iniş duraklarının % 36'sını tahmin edebilmiştir. Kalan iniş durakları (% 4) için hattın o yöndeki son durağı iniş durağı olarak kabul edilmiştir.

Yolculukların binış ve iniş duraklarına göre BV matrislerini hesaplayan algoritma çalıştırılmış ve hangi duraktan hangi durağa ne kadar yolculuk talebi olduğu tespit edilmiştir. Bu BV matrisleri kullanılarak her hattın belirlenen saat dilimindeki maksimum talep düzeyi hesaplanmıştır. 30 günlük verideki hafta sonu verilerinden hesaplanan gidiş yönündeki talepler ile bir YSA algoritması eğitilirken, dönüş yönündeki talepler ile diğer bir YSA eğitilmiştir. Aynı şekilde, hafta içi günlerden elde edilen gidiş yönündeki talepler ile bir YSA eğitilirken, dönüş yönündeki talepler ile diğer YSA eğitilmiştir. YSA ile yapılan tahminler hareketli ortalamalar, ağırlıklı hareketli ortalamalar, üstel düzeltme ve regresyon yöntemleriyle karşılaştırılmıştır. Yöntemleri performans açısından karşılaştırırken MSE, RMSE, MAD, MAPE gibi ölçütler kullanılmıştır. YSA ile yapılan tahminlerin gerçek verilere daha yakın olduğu gözlenmiştir.

Konak bağlantılı en yoğun on hat için en yoğun saatteki optimum sefer sıklıkları geliştirilen 14 matematiksel model için önerdiğimiz basit algoritmik yaklaşım ve genetik algoritma ile hesaplanmıştır. Yapılan testler her iki algoritmanın da optimum sonuç verdiğini göstermiştir. Genetik algoritmaların optimum sonuç vermesi garanti edilemese de probleme özel başarılı çaprazlama ve mutasyon operatörü kullanılarak daha iyi sonuç alınması mümkündür. Bu çalışmada önerdiğimiz algoritmik yaklaşıma benzer bir mutasyon operatörü kullanılmıştır. Bu nedenle genetik algoritmanın 500 nesilde optimum sonuç ürettiği görülmüştür. Araç içi kalabalıklığa bir standart getirmesi ve yolcuların durakta bekleme süresi ile maliyeti

de minimize etmeye çalışması nedeniyle model 14'ün kullanımının daha uygun olduğu düşünülmüştür. Optimizasyon algoritmalarının model 14'e göre hesapladığı sefer sıklığı ile ESHOT'un uyguladığı sefer sıklıkları 63, 802 ve 171 nolu hatlarda birbirine yakın bulunmuştur. Bu hatlar için ESHOT'un çizelgesinin optimuma yakın olduğu söylenebilir. ESHOT'un 554, 169, 23, 285, 193 ve 465 nolu hatlarda uyguladıkları çizelgede, hesaplanan optimum sefer sıklıklarından çok düşük düzeyde sefer düzenlendiği belirlenmiştir. İşletme maliyeti ve verimlilik açısından ESHOT Genel Müdürlüğü'nün çizelgeleri yeterli ve talebi karşılıyor olabilir. Ancak, bu çizelgelerde yolcuların durakta bekleme süreleri ve m^2 'ye düşen yolcu sayılarının daha yüksek olduğu görülmüştür. Bu durum yolcuların memnuniyetini olumsuz etkilemektedir. Özellikle 285, 193 ve 465 nolu hatlarda m^2 'ye düşen yolcu sayısının 4'ten fazla olduğu görülmüştür. Bu değerler bu hatlardaki otobüsler aşırı kalabalık olduklarını göstermektedir. Ayrıca yolcuların durakta bekleme sürelerinin de bu hatlarda oldukça uzun olduğu görülmüştür. ESHOT Genel Müdürlüğü'nün bu hatlara daha fazla otobüs tahsis ederek sefer sıklığını arttırması yolcuların kalite değerlendirmesi bakımından oldukça faydalı olacaktır.

Araştırma sonuçları akıllı kart verileri yardımıyla gelecek öngörüsünde bulunulabileceği, yolcuların biniş ve iniş yaptıkları duraklara ve zamana göre sınıflandırılabilceği, istenilen bir hat için istenilen bir saatte optimum sefer sıklığının belirlenebileceği gözlenmiştir.

Bu çalışmanın en önemli sınırlılıklarından birisi güçlü bir sunucu bilgisayar olmaması nedeniyle işlemlerin çok uzun zaman almasıdır. Bu nedenle sınırlı sayıda hat üzerinde algoritma test edilebilmiştir. Önemli bir sınırlılık ise veri miktarının gelecek öngörüsü için çok yeterli olmamasıdır. Belediyelerdeki güçlü sunucularda bu algoritmanın daha fazla veri üzerinde çalıştırılması durumunda daha sağlıklı gelecek öngörüler elde edilebilir. Bu çalışmada hatlardaki hizmet güvenilirliği incelenmemiştir. Gelecek çalışmalarda hizmet güvenilirliği de incelenebilir. Veri madenciliği teknikleri ile yolcuların davranışları analiz edilebilir.

Bu çalışmada hatlar için görevlendirilen körüklü ve solo otobüs sayıları veritabanından hesaplanmış sabit verilerdir. Bu veriler incelendiğinde bazı hatlara fazla sayıda bazılarına ise az sayıda otobüs tahsis edildiği görülmüştür. Hatlara araç tahsisini de gerçekleştiren bir genetik algoritma ile hem hatlara gereken sayıda otobüs

görevlendiren hem de hat için en optimum sefer sıklığını hesaplayan bir algoritma geliştirilebilir.

Belediyelerin akıllı kart verilerinden bu çalışmada gösterildiği gibi faydalanabilmeleri için yazılım geliştirme konusunda uzman, büyük veri analizi, veri madenciliği teknikleri ve yapay zeka konusunda deneyimli personel istihdam etmeleri ve bu tarz projeler geliştirmeleri daha doğru kararlar almalarına yardımcı olacaktır. Yeni akıllı kart sistemlerinde iniş durakları da belirli olacağından yolculuk zincirleme algoritması gibi zorlu algoritmalara gerek olmayacaktır ve tahmini değil gerçek iniş durakları ile çalışılacağından gelecek öngörüler daha sağlıklı olacaktır. Belediyelerin bu nedenle iniş duraklarını da kaydedebilen akıllı kart sistemlerine yatırım yapmaları faydalı olacaktır.



6. KAYNAKÇA

Abrahamsson, T. (1998). *Estimation of origin-destination matrices using traffic counts-a literature survey*. IIASA interim report. Laxenburg, Austria.

Ackley, D., Hinton, G. ve Sejnowski, T. (1985). A Learning Algorithm for Boltzmann Machines. *Cognitive Science*. 9: 147-169.

Adamowski, J., Chan, H., Prasher, S., Ozga-Zielinski, B. ve Sliusarieva, A. (2012). Comparison of multiple linear and nonlinear regression, autoregressive integrated moving average, artificial neural network, and wavelet artificial neural network methods for urban water demand forecasting in Montreal, Canada. *Water Resources Research*. 48: 1-14.

Adeli, H. ve Kumar, S. (1995). Concurrent Structural Optimization on Massively Parallel Supercomputer. *Journal of Structural Engineering*. 121 (11): 1588 – 1597.

Adıyaman, F. (2007). *Talep Tahmininde Yapay Sinir Ağlarının Kullanılması*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.

Agard, B., Morency, C. ve Trépanier, M. (2006). Mining Public Transport User Behaviour from Smart Card Data. *IFAC Proceedings Volumes*. 39(3): 399–404.

Agrawal, R. ve Srikant, R. (1995). Mining Sequential Patterns. *Proceedings of the Eleventh International Conference on Data Engineering (ICDE '95)* (ss. 3-14). Washington: IEEE Computer Society.

Agrawal, R., Imielinski, T. ve Swami, A. (1993). Mining Association Rules between Sets of Items in Large Databases. *Proceedings of the 1993 ACM SIGMOD international conference on Management of data (SIGMOD '93)* (ss. 207-216). New York: ACM.

Ağaoğlu, M.C. (2009). Trafik Sayımları, Bölge Nüfusları Ve Bölgeler Arası Uzaklıkları Kullanarak Başlangıç-Son Matrisi Tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*. 24 (1): 129-136.

Akbulut, S. (2006). *Veri Madenciliği Teknikleri ile Bir Kozmetik Markanın Ayrılan Müşteri Analizi Ve Müşteri Segmentasyonu*. (Yayınlanmamış Yüksek Lisans Tezi). Ankara: Gazi Üniversitesi Fen Bilimleri Enstitüsü.

Akdeniz Dura, E., Pamukcu, A. ve Bozkurt, H. (2014). Comparison Of Data Mining Techniques For Direct Marketing Campaings. *Mühendislik ve Fen Bilimleri Dergisi (SİGMA)*. 32: 142-152.

Alaeddinoğlu, M., Aydın, T. ve Dal, D. (2012). Birliktelik Kuralları İle Mekânsal-Zamansal Veri Madenciliği. *EÜFBED - Fen Bilimleri Enstitüsü Dergisi*. 5 (2): 191-212.

Albayrak, A. (2009). Classification of Domestic and Foreign Commercial Banks in Turkey Based On Financial Efficiency: A Comparison of Decision Tree, Logistic Regression and Discriminant Analysis Models. *S.D.Ü. İktisadi ve İdari Bilimler Fakültesi Dergisi*. 14 (2): 113-139.

Albayrak, A. ve Yılmaz, Ş. (2009). Veri Madenciliği: Karar Ağacı Algoritmaları ve İMKB Verileri Üzerine Bir Uygulama. *S.D.Ü. İktisadi ve İdari Bilimler Fakültesi Dergisi*. 14 (1): 31-52.

Alp, S. (2008). *Doğrusal Hedef Programlama Yöntemi Kullanılarak Kentiçi Otobüsle Toplu Taşıma Sistemi İçin Bir Model Oluşturulması Ve Uygulanması*. (Yayınlanmamış Doktora Tezi). İstanbul: Marmara Üniversitesi Sosyal Bilimler Enstitüsü.

Alsger, A., Assemi, B., Mesbah, M. ve Ferreira, L. (2016). Validating and improving public transport origin–destination estimation algorithm using smart card fare data. *Transportation Research Part C*. 68: 490-506.

Altınıřık, K. (2013). *İnsansız Bir Hava Tařıtının Kentiçi Harita Üzerinde Konumlandırılması ve Hedef Nokta İin Yönelme Algoritmasının Geliřtirilmesi*. (Yayımlanmamıř Yüksek Lisans Tezi). İzmir: Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü.

Altuntař, S. ve Selim, H. (2012). Facility layout using weighted association rule-based data mining algorithms: Evaluation with simulation. *Expert Systems with Applications*. 39: 3-13.

Amaya, M., Cruzat, R. ve Munizaga, M.A. (2018). Estimating the residence zone of frequent public transport users to make travel pattern and time use analysis. *Journal of Transport Geography*. 66: 330–339.

Antony, S. ve Jayarajan, J. N. (2015). T-GEN. A Tabu Search Based Genetic Algorithm for the Automatic Playlist Generation Problem. *Procedia Computer Science*. 46 : 409-416.

Argüden, Y. ve Erřahin, B. (2008). *Veri Madencilięi (Veriden Bilgiye, Masraftan Deęere)*. İstanbul: ARGE Danıřmanlık A.ř.

Ashley, D., Richardson, T. ve Young, D. (2009) Recent Information on the Under-reporting of Trips in Household Travel Surveys. *32nd Australasian Transport Research Forum (ATRF)*. Auckland, New Zealand.

Asilkan, Ö. ve Irmak, S. (2009). İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları İle Tahmin Edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 14 (2): 375-391.

Ata, A. ve Seyrek, İ. (2009). The Use of Data Mining Techniques in Detecting Fraudulent Financial Statements: An Application on Manufacturing Firms. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 14 (2): 157-170.

Ata, N., Özkök, E. ve Karabey, U. (2007). Survival Data Mining: An Application To Credit Card Holders. *Sigma Mühendislik ve Fen Bilimleri Dergisi*. 26 (1): 33-42.

Ataseven, B. (2013). Yapay Sinir Ağları İle Öngörü Modellemesi. *Öneri Dergisi*. 10 (39): 101-115.

Attoh-Okine, N.O., Shen, L.D. 1995. Security issues of emerging smartcard fare collection application in mass transit. *IEEE Vehicle Navigation and Information Systems Conference Proceedings., In conjunction with the Pacific Rim TransTech Conference., Sixth International VNIS., A Ride into the Future* (ss. 523-526). 30 July- 2 Aug. 1995.

Bae, J. ve Kim, J. (2011). Product development with data mining techniques: A case on design of digital camera. *Expert Systems with Applications*. 38: 9274-9280.

Barreto, A.M.S., Barbosa, H.J.C. ve Ebecken, N.F.F. (2006). GOLS—Genetic orthogonal least squares algorithm for training RBF networks. *Neurocomputing*. 69: 2041 – 2064.

Barry, J.J., Freimer, R. ve Slavin, H. (2009). Use of Entry-Only Automatic Fare Collection Data to Estimate Linked Transit Trips in New York City. *Transportation Research Record*. 2112: 53-61.

Barry, J.J., Newhouser, R., Rahbee, A. ve Sayeda, S. (2002). Origin and Destination Estimation in New York City with Automated Fare System Data. *Transportation Research Record*. 1817: 183–187.

Bashar, A. -S. (2007). Mass customization of travel packages: Data mining approach. *International Journal of Flexible Manufacturing Systems*. 19: 612-624.

Batarce, M., Muñoz, J.C., Ortúzar, J.D., Raveau, S., Mojica, C. ve Ríos, R.A. (2015). *Evaluation of Passenger Comfort in Bus Rapid Transit Systems*. Technical Note No. IDB-TN-770. Inter - American Development Bank, Infrastructure and Environment Sector, Transport Division. Washington, DC, US.

Baykal, A. (2006). Veri Madenciliği Uygulama Alanları. *D. Ü. Ziya Gökalp Eğitim Fakültesi Dergisi*. 7: 95-107.

Bean, J.C. (1994). Genetic Algorithms and Random Keys for Sequencing and Optimization. *ORSA Journal on Computing*. 6 (2): 107 – 220.

Bengio, Y. , Thibodeau – Laufer, E. ve Alain, G. (2014). Deep Generative Stochastic Networks Trainable by Backprop. *Proceedings of the 31 st International Conference on Machine Learning*. Beijing, China. JMLR: W&CP. 32: II – 226, II – 234.

Berenji, H. (1992). An architecture for designing fuzzy controllers using neural networks. *International Journal Approximate Reasoning*. 6 (2): 267-292.

Biroğul, S. (2005). *Genetik Algoritma Yaklaşımıyla Atölye Çizelgeleme*. (Yayınlanmamış Yüksek Lisans Tezi). Ankara: Gazi Üniversitesi , Fen Bilimleri Enstitüsü.

Blythe, P. (1998) Integrated Ticketing Smart Cards in Transport. *IEEE Colloquium: Using ITS in Public Transport and in Emergency Services*. December 1998.

Blythe, P. 2004. Improving public transport ticketing through smart cards. *Proceedings of the Institute of Civil Engineers, Municipal Engineer*. 157: 47-54.

Boser, B., Guyon, I. ve Vapnik, V. (1992). A training algorithm for optimal margin classifiers. *Proceedings of the fifth annual workshop on Computational learning theory (COLT '92)* (ss. 144-152). New York, NY, USA.

Bricka, S. ve Bhat, C. (2006). Comparative Analysis of Global Positioning System-based and Travel Survey-based Data. *Transportation Research Record: Journal of the Transportation Research Board*. (1972): 9-20.

Broomhead, D. ve Lowe, D. (1988). *Radial Basis Functions, Multi-Variable Functional Interpolation And Adaptive Networks*. DTIC Document.

Buntine, W. ve Weigned, A. (1991). Bayesian backpropagation. *Complex Systems*. 5 (6): 603-643.

Burmaoğlu, S., Oktay, E. ve Özen, Ü. (2009). Birleşmiş Milletler Kalkınma Programı Beşeri Kalkınma Endeksi Verilerini Kullanarak Diskriminant Analizi Ve Lojistik Regresyon Analizinin Sınıflandırma Performanslarının Karşılaştırılması. *Savunma Bilimleri Dergisi*. 8 (2): 23-49.

Carpenter, G.A. ve Grossberg, S. (1986). Category Learning and Adaptive Pattern Recognition: A Neural Network Model. *Proceedings of the 3rd Army Conference on Applied Mathematics and Computing, ARO* (ss. 37-56). Report 86-1.

Carpenter, G.A. ve Grossberg, S. (1987). Art2: Self-Organization Of Stable Category Recognition Codes For Analog Input Patterns. *Applied Optics*. 26: 4919-4930.

Carrion, C., Pereira, F., Ball, R., Zhao, F., Kim, Y., Nawarathne, K., Zheng, N., Zegras, C. ve Ben-Akiva, M. (2014). Evaluating Fms: A Preliminary Comparison with a Traditional Travel Survey. *Transportation Research Board 93rd Annual Meeting*. Washington DC. 12 – 16 Ocak.

Ceylan, Z., Gürsev, S. ve Bulkan, S. (2017). İki Aşamalı Kümeleme Analizi ile Bireysel Emeklilik Sektöründe Müşteri Profilinin Değerlendirilmesi. *Bilişim Teknolojileri Dergisi*. 10 (4): 475-485.

Charnes, A. ve Cooper, W.W. (1961). *Management Models and the Industrial Applications of Linear Programming (Volume I)*. New York: John Wiley and Sons.

Charnes, A., Cooper, W.W. ve Ferguson, R.O. (1955). Optimal Estimation of Executive Compensation by Linear Programming. *Management Science*. 1 (2): 138-151.

Charon, I. ve Hudry, O. (1998). Lamarckian Genetic Algorithms Applied to The Aggregation Of Preferences. *Annals of Operations Research*. 80: 281 – 297.

Chiu, C. ve Yih, Y. (1995). A Learning-Based Methodology For Dynamic Scheduling In Distributed Manufacturing Systems. *International Journal of Production Research*. 33 (11): 3217 – 3232.

Chua, L. ve Lin, Y. (1988). Cellular neural networks: theory. *IEEE Transactions on Circuits and Systems*. 35 (10): 1257-1272.

Cirulis, A. ve Brigmanis, K.B. (2013). 3D Outdoor Augmented Reality for Architecture and Urban Planning. *Procedia Computer Science*. 25: 71-79.

Cormier, D., Grady, P.O. ve Sanii, E. (1998). A constraint-based genetic algorithm for concurrent engineering. *International Journal of Production Research*, 36 (6): 1679-1697.

Coşlu, E. (2013). Veri Madenciliği. *XV. Akademik Bilisim Konferansı* (ss. 573-577). Düzenleyen Akdeniz Üniversitesi Antalya.

Cottrill, C., Pereira, F., Zhao, F., Dias, I., Lim, H., Ben-Akiva, M. ve Zengras, P. (2013). Future Mobility Survey: Experience in Developing a Smartphone-based Travel Survey in Singapore. *Transportation Research Record: Journal of the Transportation Research Board*. (2354): 59- 67.

Çelik, B. (2008). *Yapay Sinir Ağları Metodolojisi ile Zaman Serisi Analizi*. (Yayınlanmamış Yüksek Lisan Tezi). İstanbul: Marmara Üniversitesi Sosyal Bilimler Enstitüsü.

Çelik, U., Akçetin, E. ve Gök, M. (2017). *Rapidminer ile Uygulamalı Veri Madenciliği*. İstanbul: Pusula 20 Teknoloji ve Yayıncılık.

Çınarlıoğlu, S. (2015). Ankara Metropolitan Alanda Bulunan Hastanelerin İtibar Ve İmaj Algısı Açısından Kümelenmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 20 (1): 277-29.

Çöllüoğlu Gülen, Ö. ve Özdemir, S. (2013). Veri Madenciliği Teknikleri İle Üstün Yetenekli Öğrencilerin İlgi Alanlarının Analizi. *Üstün Yetenekliler Eğitimi Araştırmaları Dergisi*. 1 (3): 213-226.

Çuhadar, M. (2006). *Turizm Sektöründe Talep Tahmini İçin Yapay Sinir Ağları Kullanımı Ve Diğer Yöntemlerle Arşılaştırmalı Analizi (Antalya İlinin Dış Turizm Talebinde Uygulama)*. (Yayınlanmamış Doktora Tezi). Isparta: Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü.

Çuhadar, M. ve Kayacan, C. (2005). Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye’deki Konaklama İşletmeleri Üzerine Bir Deneme . *Anatolia: Turizm Araştırmaları Dergisi*. 16 (1): 24-30.

Çuhadar, M., Güngör, İ. ve Göksu, A. (2009). Turizm Talebinin Yapay Sinir Ağları İle Tahmini Ve Zaman Serisi Yöntemleri İle Karşılaştırmalı Analizi: Antalya İline Yönelik Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 14 (1): 99-114.

Da Silva, E.L., Gil, H.A. ve Areiza, J.M. (2000). Transmission Network Expansion Planning Under an Improved Genetic Algorithm. *IEEE Transactions on Power Systems*. 15 (3): 1168 – 1174.

Dagli, C.H. ve Sittisathanchai, S. (1995). Genetic neuro-scheduler: A new approach for job shop scheduling. *International Journal of Production Economics*. 41 (1 – 3): 135 – 145.

Dai, K. ve Wang, N. (2012). A hybrid DNA based genetic algorithm for parameter estimation of dynamic systems. *Chemical Engineering Research and Design*. 90 (12): 2235-2246.

Das, A., Ng, W. ve Woon, Y. (2001). Rapid Association Rule Mining. *Proceedings of the Tenth International Conference on Information and Knowledge Management (ss. 487-499)*. Atlanta: ACM Press.

Davis, L. (1989). Adapting Operator Probabilities in Genetic Algorithms. *Proceedings 3rd International Conference on Genetic Algorithms and Their Applications* (ss. 61 – 69). George Mason University.

De Jong, K.A. (1975). *Analysis Of The Behavior Of A Class Of Genetic Adaptive Systems*. (Yayınlanmamış Doktora Tezi). Ann Arbor: University of Michigan. Department of Computer and Communication Science.

Delice, Y. (2012). *Otomatik Ücretlendirme Sistemi Verileri Kullanılarak İstanbul Geneli Toplu Taşıma Başlangıç – Son Matrisi Tahmini İçin Bir Yöntem*. (Yayımlanmamış Doktora Tezi). İstanbul: İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.

Demirel, N., Gökçen, H., Akçayol, M. ve Demirel, E. (2011). Çok Aşamalı Bütünleşik Lojistik Ağı Optimizasyonu Probleminin Melez Genetik Algoritma İle Çözümü. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*: 26 (4): 929-936.

Dempsey, P. S. (2015). Privacy Issues with the Use of Smart Cards. https://papers.ssrn.com/sol3/Delivery.cfm/SSRN_ID2692652_code372699.pdf?abstr actid=2692652&mirid=1. (23.12.2019).

Deri, A. (2012). *Akıllı Kart Verileri Kullanılarak Toplu Ulaşım Yolculuk Talebinin Belirlenmesi Ve Sefer Çizelgeleme Optimizasyonu*. (Yayımlanmamış Yüksek Lisans Tezi). İzmir: Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü.

Desjardins, G. ve Bengio, Y. (2008). Empirical evaluation of convolutional RBMs for vision. Technical Report 1327, *Département d'Informatique et de Recherche Op'erationnelle, Université de Montr'eal*, 2008.

Devillaine, F., Munizaga, M. ve Trépanier, M., (2012). Detection of activities of public transport users by analyzing smart card data. *Transportation Research Record: Journal of the Transportation Research Board*. (2276): 48-55.

Devillaine, F., Munizaga, M.A., Palma, C. ve Zúñiga, M., (2013). Towards a reliable Origin-Destination matrix from massive amounts of Smartcard and GPS data: application to Santiago. *Transport Survey Methods; Best Practice for Decision Making* (ss. 695–710). Editors Zmud, J., Lee-Gosselin, M., Munizaga, M.A., Carrasco, J.A., Emerald.

Diec, J., Coxon, S. ve de Bono, A. (2010). Designing a public train station shelter to minimise anti-social behaviour and crime in Melbourne's metropolitan rail environment. *Paper presented at the 33rd Australasian Transport Research Forum*. Canberra, Australia.

Diker, A. C. (2015). *Usage Of Fuzzy Logic Based Data Mining Methods In Analysis Of Public Transportation Data*. (Yayımlanmamış Doktora Tezi). İzmir: Dokuz Eylül Üniversitesi Fen Bilimleri Enstitüsü.

Dinler, M. (2014). *Kümeleme Analizi Yöntemlerinin Hayvancılık Verilerinde Karşılaştırılmalı Olarak İncelenmesi*. (Yayımlanmamış Yüksek Lisans Tezi). Bingöl: Bingöl Üniversitesi Fen Bilimleri Enstitüsü.

Doğan, O. (2017). Türkiye’de Veri Madenciliği Konusunda Yapılan Lisansüstü Tezler Üzerine Bir Araştırma. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 19 (3): 929-951.

El - Geneidy, A., Horning, J. ve Krizek, K. (2011). Analyzing transit service reliability using detailed data from. *Journal Of Advanced Transportation*. (45): 66-79.

El Mahrsi, M., Côme, E., Oukhellou, L. ve Verleysen, M. (2017). Clustering Smart Card Data for Urban Mobility Analysis. *IEEE Transactions On Intelligent Transportation Systems*. 18 (3): 712-728.

Eldemir, F., Akad, M. ve Deli, A. (2015). Istanbul's BRT Trip Destination Estimation and Validation. *Proceedings of the 2nd Global Conference on Engineering and Technology Management* (ss.32-38). Chicago, IL, USA. September 4 – 5.

Eliyi, U. ve Eliyi, D. (2014). Akıllı Kart Engelli Yolcu Biniş Verileri İle Yolculuk Örüntü Analizi Ve Özel Hat Çizelgeleme. *TRANSİST 2014 - 7.Uluslararası Ulaşım Teknolojileri Sempozyumu ve Fuarı* (s. 97-106). İstanbul.

Elman, J.L. (1990). Finding Structure in Time. *Cognitive Science*. 14: 179 – 211.

EMO İzmir Şubesi. (2017). Raylı Sistemlere Elektrikli Otobüs Alternatifi Elektrikli Otobüsler Maliyeti Düşürdü. *Endüstri Mühendisleri Odası İzmir Şubesi Haziran 2017 Bülteni*.

Engin, O. ve Fırlalı, A. (2002). Genetik Algoritmalarla Akış Tipi Çizelgelemede Üreme Yöntemi Optimizasyonu. *itüdergisi/d mühendislik*: 1 (1): 35-41.

Eom, J.K., Song, J.Y. ve Moon, D.-S. (2015). Analysis of Public Transit Service Performance using Transit Smart Card Data in Seoul. *KSCE Journal of Civil Engineering*. 19 (5): 1530-1537.

Erdoğan, N. ve Esen, M. (2016). Classifying Universities in Turkey by Hierarchical Cluster Analysis. *Education and Science*. 41 (184): 363-382.

Ertuğrul, İ., Organ, A. ve Şavlı, A. (2013). Veri Madenciliği Uygulamasına İlişkin PAÜ Hastanesinde Hasta Profiline Belirlenmesi. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*. 19 (2): 97-103.

ESHOT Genel Müdürlüğü (2009). *Eshot Genel Müdürlüğü 2010-2014 Stratejik Planı Raporu*. İzmir: Strateji Geliştirme Dairesi Başkanlığı.

ESHOT Genel Müdürlüğü. (2017). *ESHOT Genel Müdürlüğü Resmi Web Sitesi*. <http://www.eshot.gov.tr/tr/KurulusAmaci/7/41>, (06/15/2017).

Espinoza, C., Munizaga, M.A., Bustos, B. ve Trépanier, M. (2018). Assessing the public transport travel behavior consistency from smart card data. *Transportation Research Procedia*. 32: 44–53.

Farley, B. ve Clark, W. (1954). Simulation of self-organizing systems by digital computer. *Transactions of the IRE Professional Group on Information Theory*. 4 (4), 76-84.

Faroqi, H., Mesbah, M. ve Kim, J. (2017). Spatial-Temporal Similarity Correlation between Public Transit Passengers Using Smart Card Data. *Journal of Advanced Transportation*. 2017: 1-14.

Farzin, J.M. (2008). Constructing an Automated Bus Origin–Destination Matrix Using Farecard and Global Positioning System Data in São Paulo, Brazil. *Transportation Reserach Record*. 2072: 30-37.

Feng, L., Xu, S., Wang, F., Liu, S. ve Qiao, H. (2019). Rough Extreme Learning Machine: a new classification method based on uncertainty measure. *Neurocomputing*. 325: 269 – 282.

Feng, S. ve Law, C. L. (2002). Assisted GPS and Its Impact on Navigation in Intelligent Transportation Systems. *Proceedings The IEEE 5th International Conference on Intelligent Transportation Systems* (ss. 926 – 931). Düzenleyen IEEE. Singapore: 3 – 6 Eylül.

Fogarty, T.C. (1989). Varying the Probability of Mutation in the Genetic Algorithm. *Proceedings of the 3rd International Conference on Genetic Algorithms, J. David Schaffer (Ed.)* (pp.104 – 109). San Francisco: Morgan Kaufmann Publishers Inc.

Fonzone, A., Schmöcker, J.D. ve Liu, R. (2015). A model of bus bunching under reliability-based passenger arrival patterns. *Transportation Research Procedia*. 7: 276 – 299.

Frost, A. (1988). *The Principles and Practice of Navigation*. Glasgow: Brown, Son & Furguson.

Frumin, M. ve Zhao, J. (2012). Analyzing passenger incidence behavior in heterogeneous transit services using smartcard data and schedule-based assignment. *Transportation Research Record: Journal of Transportation Research Board*. 2274 (1): 52–60.

Fu, Q., Liu, R. ve Hess, S. (2012). A review on transit assignment modelling approaches to congested networks: a new perspective. *Procedia - Social Behavioral Sciences*. 54: 1145 - 1155.

Fukushima, K. (1975). Cognitron: A Self-organizing Multilayered Neural Network. *Biological Cybernetics*. 20: 121-136.

Fukushima, K. and Miyake, S. (1982). Neocognitron,: A new algorithm for pattern recognition tolerant of deformations and shifts in position. *Pattern Recognition*. 15 (6): 455-469.

Gallagher, M. ve Downs, T. (1997). Visualisation learning in neural networks using principal component analysis. *Proseeding of the International Conference on computational intelligence and multimedia applications*, (s. 327-331).

Ge, J. and Xu, J. (2013). Stability Switches and Fold-Hopf Bifurcations in An Inertial Four-Neuron Network Model With Coupling Delay. *Neurocomputing*. 110: 70-79.

Gentile, G., Florian, M., Hamdouch, Y., Cats, O. ve Nuzzolo, A. (2016). The theory of transit assignment: basic modelling frameworks. *Modelling Public Transport Passenger Flows in the Era of Intelligent Transport Systems*. (pp. 287–386). Gentile, G., Noekel, K. (Eds.). Springer.

Ghosh, S. ve Maiti, J. (2014). Data mining driven DMAIC framework for improving foundry quality – a case study. *Production Planning & Control*: 25 (6): 478-493.

Goldberg, D. (1985). *Optimal Initial Population Size For Binary-Coded Genetic Algorithms*. TCGA Report Number 8510001, Alabama: Department of Engineering Mechanics, University of Alabama.

Goldberg, D. (1989). *Genetic Algorithms in Search, Optimization, and Machine Learning*. Boston, MA, USA: Addison-Wesley Longman Publishing Co., Inc.

Gonalves, J.F. ve Resende, M.G.C. (2011). Biased random-key genetic algorithms for combinatorial optimization. *Journal of Heuristics*. 17 (5): 487 – 525.

Gong, H., Chen, C., Bialostozky, E. ve Lawson, C. T. (2012) A GPS/GIS Method for Travel Mode Detection in New York City. *Computers, Environment and Urban Systems*. 36 (2): 131-139.

Goodfellow, I.J., Pouget-Abadie, J., Mirza, M., Warde-Farley, D., Ozair, S., Courville, A. ve Bergio, Y. (2014). Generative Adversarial Networks. *arXiv preprint arXiv: 1701.00160*. <https://arxiv.org/pdf/1406.2661.pdf>. (27.07.2019)

Grefenstette, J.J. (1986). Optimisation Of Control Parameters For Genetic Algorithms. *IEEE Transactions on Systems, Man and Cybernetics*. SMC-16 (1): 122 – 128.

Grigorenko, I. ve Garcia, M. E. (2000). An evolutionary algorithm to calculate the ground state of a quantum system. *Physica A*. 284: 131 - 139.

Grossberg, S. (1976). Adaptive Pattern Classification and Universal Recoding: II. Feedback, Expectation, Olfaction, Illusions. *Biological Cybernetics*. 23 (4): 187-202.

Gudmundsson, H., Hall, R.P., Marsden, G. ve Zietsman, J. (2010). *Sustainable Transportation. Indicators, Frameworks and Performance Management*. Berlin: Springer-Verlag.

Güllüoğlu, S. (2011). Tıp ve Sağlık Hizmetlerinde Veri Madenciliği Çalışmaları: Kanser Teşhisine Yönelik Bir Ön Çalışma. *AJIT-e: Online Academic Journal of Information Technology*. 2 (5): 1-7.

Güntürk, F. (2007). *A Comprehensive Review Of Data Mining Applications In Quality Improvement And A Case Study*. (Yayınlanmamış Yüksek Lisans Tezi). Ankara: Orta Doğu Teknik Üniversitesi.

Gürbüz, F., Özbakır, L. ve Yapıcı, H. (2009). Türkiye’de Bir Havayolu İşletmesine Ait Parça Söküm Raporlarına İlişkin Veri Madenciliği Uygulaması. *Gazi Üniversitesi Mimarlık Mühendislik Fakültesi Dergisi*. 24 (1): 73-78.

Gürsoy, U. (2010). Customer churn analysis in telecommunication sector. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*. 39 (1): 35-49.

Hacıoğlu, H. K. (2016). *Kümeleme Analizinde Kullanılan Bazı Benzerlik İndekslerinin Karşılaştırılması*. (Yayınlanmamış Yüksek Lisans Tezi). Ankara: Gazi Üniversitesi Fen Bilimleri Enstitüsü.

Han, J., Kamber, M. ve Pei, J. (2012). *Data Mining Concepts And Techniques*. Waltham, Massachusetts: Elsevier Inc.

He, M. (1993). *Theory, application and related problems of double parallel feedforward neural Networks*. (Yayınlanmamış Doktora Tezi). Xi'an, China: Xidian University.

Hendrickson, C. and McNeil, S. (1984). Estimation of origindestination matrices with constrained regression. *Transportation Research Record*. 976: 25-32.

Hendrickson, C. and McNeil, S. (1985). A regression formulation of the matrix estimation problem, *Transportation Science*, 19: 278-292.

Herrera, F., Lozano, M. ve Verdegay, J. L. (1998). Tackling Real-Coded genetic Algorithms: operators and Tools for Behavioral Analysis. *Artificial Intelligence Review*. 12 (4): 265-319.

Hinton, G.E., Osindero, S. and Teh, Y.- W. (2006). A fast learning algorithm for deep belief nets. *Neural Computation*. 18 (7): 1527-1554.

Hoche, S., Geist, I., Castillo, L. P. ve Schulz, N. (2006). Databases, Knowledge Discovery, Information Retrieval, and Web Mining. *CIGR Handbook of Agricultural Engineering Volume VI Information Technology* (Editör: A. Munack - Çeviren S. Tarhan vd.) (s. 168-184). Michigan, USA: American Society of Agricultural Engineers.

Holland, J. (1975). *Adaptation in Natural and Artificial Systems*. Ann Arbor: University of Michigan Press.

Holroyd, E. M. ve Scraggs, D. A. (1966). Waiting Time for Buses in Central London. *Traffic Engineering and Control*. 8: 158-160.

Hong, W. -C., Dong, Y., Chenc, L. -Y., ve Wei, S. -Y. (2011). SVR with hybrid chaotic genetic algorithms for tourism demand forecasting. *Applied Soft Computing*. 11: 1881-1890.

Hopfield, J. (1982). Neural Networks and Physical System with emergent collective computational abilities. *Proceedings of National Academy of Science*. 79: 2554-2558.

Hora, J., Dias, T.G., Camanho, A., ve Sobral, T. (2017). Estimation of Origin-Destination matrices under Automatic Fare Collection: the case study of Porto transportation system. *Transportation Research Procedia*. 27: pp.664–671.

Houtsma, M., ve Swami, A. (1995). Set-oriented mining for association rules in relational databases. *Proceedings of the Eleventh International Conference on Data Engineering*, (s. 25-33). Taipei.

Hsu, K. (2011). Using a back propagation network combined with grey clustering to forecast policyholder decision to purchase investment-linked insurance. *Expert Systems with Applications*. 38 (6): 6736-6747.

Hu, P. S. ve Reuscher, T. R. (2004) *Summary of Travel Trends: 2001 National Household Travel Survey*. U. S. Department of Transportation and Federal Highway Administration.

Hu, P. S. ve Young, J. (1999) *Summary of Travel Trends : 1995 Nationwide Personal Transportation survey*. Springfield: U.S. Department of Transportation and Federal Highway Administration.

Huang, G., Zhu, Q., ve Siew, C. (2006). Extreme learning machine: Theory and applications. *Neurocomputing*. 70: 489-501.

Huang, Y., Gedeon, T.D. ve Wong, P.M. (2001). An integrated neural-fuzzy-genetic-algorithm using hyper-surface membership functions to predict permeability in petroleum reservoirs. *Engineering Applications of Artificial Intelligence*. 14: 15 - 21.

Hutter, M. (2002). Fitness uniform selection to preserve genetic diversity. *Proceedings of the 2002 Congress on Evolutionary Computation (CEC-2002)* (s. 783-788). Washington D.C, USA: IEEE.

Ijiri, Y. (1965). Management Goals and Accounting for Control. *Studies in Mathematical and Managerial Economics, volume 3*. Amsterdam: North-Holland Publishing Company.

Ingvardson, J.B., Nielsen, O.A. ve Raveau, S. (2018). Passenger arrival and waiting time distributions dependent on train service frequency and station characteristics: A smart card data analysis. *Transportation Research Part C*. 90: 292 – 306.

Işık, M. ve Çamurcu, A. (2008). Web Belgeleri Kümelemede Benzerlik Ve Uzaklık Ölçütleri Başarılarının Karşılaştırılması. *Marmara Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. 20: 35 - 49.

İşli, D. (2009). *Veri Ambarı Ve Olap Teknolojilerinden Yararlanılarak Raporlama Aracı Gerçekleştirimi*. (Yayınlanmamış Yüksek Lisans Tezi). Denizli: Pamukkale Üniversitesi Fen Bilimleri Enstitüsü.

Jones, A., ve Rabelo, J. C. (1998). *Survey of Job Shop Scheduling Techniques*. (Technical report), NISTIR, National Institute of Standards and Technology, Gaithersburg, MD.

Jun, C. ve Dongyuan, Y. (2013). Estimating Smart Card Commuters Origin-Destination Distribution Based on APTS Data. *Journal Of Transportation Systems Engineering And Information Technology*. 13 (4): 47-53.

Kak, S. (1995). Quantum Neural Computing. *Advances in Imaging and Electron Physics*. 94: 259-314.

Kalikov, A. (2006). *Veri Madenciliği ve Bir E-Ticaret Uygulaması*. (Yayınlanmamış Yüksek Lisans Tezi). Ankara: Gazi Üniversitesi Fen Bilimleri Enstitüsü.

Kalkınma Bakanlığı. (2015). *Bilgi Toplumu Stratejisi ve Eylem Planı 2015-2018*. <http://www.bilgitoplumustratejisi.org/tr/doc/8a9481984680deca014bea42> 32490005: file:///E:/downloads/20152018_bilgi_toplumu_stratejisi_ve_eylem_plani.pdf. (15.06.2019).

Kaplan, E. ve Hegarty, C. (2005) *Understanding GPS: Principles and Applications (Second Edition)*. London: Artech House.

Karaboğa, D. (2004). *Yapay Zeka Optimizasyon Algoritmaları*. İstanbul: Atlas Yayın Dağıtım.

Karahan, M. (2015). Yapay Sinir Ağları Metodu İle İhracat Miktarlarının Tahmini: ARIMA ve YSA Metodunun Karşılaştırmalı Analizi. *Ege Akademik Bakış Dergisi*. 15 (2): 165-172.

Kasprzyk, G.P. ve Jaskula, M. (2004). Application of the hybrid genetic-simplex algorithm for deconvolution of electrochemical responses in SDLSV method. *Journal of Electroanalytical Chemistry*. 567: 39 - 66.

Kaşıkcı, T. ve Gökçen, H. (2014). Metin Madenciliği ile E-Ticaret Sitelerinin Belirlenmesi. *Bilişim Teknolojileri Dergisi*. 7 (1): 25-32.

Kavzoğlu, T. (2001). *An Investigation Of The Design And Use Of Feed-Forward Artificial Neural Networks In The Classification Of Remotely Sensed Images*. (Yayınlanmamış Doktora Tezi). The University of Nottingham.

Kaynar, O., ve Taştan, S. (2000). Zaman Serisi Analizinde Mlp Yapay Sinir Ağları Ve ARIMA Modelinin Karşılaştırılması. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 33: 161-172.

Khanadar, A., Sharma, B., ve Srivastava, S. (2016). Data Mining from Smart Card Data using Data Clustering. *International Journal of Applied Engineering Research*. 11 (1): 347-352.

Kheirkhah, A., Azadeh, A., Saberi, M., Azaron, A. ve Shakouri, H. (2013). Improved estimation of electricity demand function by using artificial neural network, principle component analysis and data envelopment analysis. *Computers & Industrial Engineering*. 64: 425-441.

Kılınçaslan, T., Elker, C. ve Babalık Sutcliffe, E. (2017). *Kentsel Ulaşım (Ulaşım Sistemi – Toplu Taşıım Planlama – Politikalar)*. İstanbul: Ninova Yayınları.

Kim, J.Y., Kim, Y.K. ve Cho, Y. (1998). A Heuristic-Based Genetic Algorithm For Workload Smoothing In Assembly Lines. *Computers & Operations Research*. 25(2): 99-111.

Kim, S., Jitpitaklert, W., Park, S., ve Hwang, S. (2012). Data mining model-based control charts for multivariate and autocorrelated processes. *Expert Systems with Applications*. 39: 2073-2081.

Koháni, M. (2015). OD Matrix Estimation Using Smart Card Transactions Data and Its Usage for the Tariff Zones Determination in the Public Transport. *Operations Research Proceedings* (s. 231-236). Vienna: Springer.

Kohonen, T. (1972). Correlation Matrix Memories. *IEEE Transactions On Computers*. 21 (4): 353-359.

Kohonen, T. (1982). Self-Organized Formation of Topologically Correct Feature Maps. *Biological Cybernetics*. 43: 59-69.

Kohonen, T. (1984). *Self Organization and Associative Memory*. New York: Springer-Verlag.

Koyuncugil, A., ve Özgülbaş, N. (2009). Veri Madenciliği: Tıp ve Sağlık Hizmetlerinde Kullanımı ve Uygulamaları. *Bilişim Teknolojileri Dergisi*. 2 (2): 21-32.

Köse, O., ve Özdemir, T. (2017). Balıkesir Kent Merkezi Toplu Ulaşımı: Akıllı Kart Verilerinin Analizi. *8th International Advanced Technologies Symposium (IATS'17)*, (s. 2217-2222), Düzenleyen Fırat Üniversitesi. Elazığ. 19-22 Ekim 2017.

Kubota, N., Fukuda, T. Ve Shimojima, K. (1996). Virus-Evolutionary Genetic Algorithm For A Self-Organizing Manufacturing System. *Computers & Industrial Engineering*. 30 (4): 1015-1026.

Kumara, S., ve Rao, C. (2009). Application of ant colony, genetic algorithm and data mining-based techniques for scheduling. *Robotics and Computer-Integrated Manufacturing*. 25: 901-908.

Kurt, Ç., ve Erdem, O. (2012). Öğrenci Başarısını Etkileyen Faktörlerin Veri Madenciliği Yöntemleriyle İncelenmesi. *Politeknik Dergisi*. 15 (2): 111-116.

LeCun, Y., Bottou, L., Bengio, Y. ve Haffner, P. (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*. 86 (11): 2278-2324.

Leduc, G. (2008) Road Traffic Data: Collection Methods and Applications. *Working Papers on Energy, Transport and Climate Change*. 1: 55.

Lee, I., Oh, S., ve Min, J. (2011). Prospect Of Technology For Public Transit Planning Using Smart Card Data. *World Congress Railway Researches - WCRR*, (s. 1-11). Lille.

Lee, S.M. (1972). *Goal Programming for Decision Analysis*. Philadelphia: Auerbach Publishers.

Lei, D. (2010). A genetic algorithm for flexible job shop scheduling with fuzzy processing time. *International Journal of Production Research*. 48 (10): 2995 – 3013.

Lewenstein, M. (1994). Quantum Perceptrons. *Journal of Modern Optics*. 41 (12): 2491-2501.

Li, Z. ve Hensher, D.A. (2013). Crowding in Public Transport: A Review of Objective and Subjective Measures. *Journal of Public Transportation*. 16 (2): 107-134.

Lianfu, Z., Shuzhi, Z., Yonggang, Z. ve Ziyin, Z. (2007). Study on the method of constructing bus stops OD matrix based on IC card data. *2007 International Conference on Wireless Communications, Networking and Mobile Computing*. (ss. 3147–3150). 21-25 Eylül.

Liao, S. -H., Chen, C. -M., ve Wu, C. -H. (2008). Mining customer knowledge for product line and brand extension in retailing. *Expert Systems with Applications*. 34: 1763-1776.

Liu, S., ve Chen, J. (2009). Using data mining to segment healthcare markets from patients' preference perspectives. *International Journal of Health Care Quality Assurance*. 22 (2): 117-134.

Lo, H.P. ve Chan, C.P. (2003). Simultaneous estimation of an origin-destination matrix and link choice proportions using traffic counts. *Transportation Research, Part A: Policy and Practice*. 37 (9): 771-788.

Luethi, M., Weidmann, U.A. ve Nash, A. (2007). Passenger arrival rates at public transport stations. Transportation Research Board 86th Annual Meeting. No. 07-063.

Ma, X. (2013). *Smart Card Data Mining and Inference for Transit System Optimization and Performance Improvement*. (Yayınlanmamış Doktora Tezi). Washington: University of Washington Department of Civil and Environmental Engineering.

Marguier, P.H.J. ve Ceder, A. (1984). Passenger Waiting Strategies for Overlapping Bus Routes. *Transportation Science*. 18 (3): 207 – 313.

Mcdonald, N. (2000) Multipurpose Smart Cards in Transportation: Benefits and Barriers to Use. UC Berkeley: University of California Transportation Center. <https://pdfs.semanticscholar.org/2567/c33634d4216fea48bf737902bb58ca49f039.pdf> (06.06.2019).

Medhi, P., Mondal, S., Jhaveri, D., ve Gupta, N. (2014). A neural feature extraction model for clustering supplier firms for supply chain collaboration. *Society of Operations Management Conference*. Roorkee: Indian Institute of Technology. December 12-14.

Melachrinoudis, E. and Xanthopoulos, Z. (2003). Semi-obnoxious single facility location in Euclidean space. *Computers & Operations Research*. 30 (14): 2191–2209.

Mintsis, G., Basbas, S., Papaioannou, P., Taxiltaris, C. ve Tziavos, I. (2004). Applications of GPS Technology in the Land Transportation System. *European Journal of Operational Research*. 152 (2): 399-409.

Montreuil, B. (2008). Facilities Location and Layout Design. *Logistics Engineering Handbook* (s. 1-56). Editor Taylor, G.D. New York: Taylor & Francis Group.

Moradi, M., Keyvanpour, M., Ardestani, M., ve Moradi, M. (2016). Applications of data mining in robotics. *2016 Artificial Intelligence and Robotics (IRANOPEN)*, (s. 18-24). Qazvin. April 09.

Morency, C., Trépanier, M. ve Agard, B. (2006). Analysing the Variability of Transit Users Behaviour with Smart Card Data. *Ninth International IEEE Conference on Intelligent Transportation Systems*. (ss. 44-49) Toronto, Canada. 17 – 20 Eylül.

Morency, C., Trépanier, M., Agard, B. (2007). Measuring Transit Performance using Smart Card Data. *World Conference on Transport Research (1-33)*. San Francisco, USA. June 24-28, 2007.

Munizaga , M.A., ve Palma, C. (2012). Estimation of a disaggregate multimodal public transport origin-destination matrix from passive Smart card data from Santiago, Chile. *Transportation Research 24C*. (12): 9–18.

Munizaga, M. A., Devillaine, F., Navarrete, C. ve Silva, D. (2014). Validating travel behaviour estimated from smartcard data. *Transportation Research Part C*. 44: 70-79.

Munizaga, M.A., Palma, C., ve Mora, P. (2010). Public Transport Od Matrix Estimation From Smart Card Payment System Data. *Presented at the 12th World Conference on Transport Research*, Lisbon,Portugal. 11-15 Haziran.

Murata, T., Ishibuchi, H. ve Tanaka, H. (1996). Multi-Objective Genetic Algorithm And Its Applications To Flowshop Scheduling. *Computers & Industrial Engineering*. 30 (4): 957-968.

Murphy, R. (2003). *A Generic Parallel Genetic Algorithm*. (Yayınlanmamış Yüksek Lisans Tezi) University of Dublin Department of Mathematics.

Mwemezi, J. and Huang, Y. (2011). Optimal Facility Location on Spherical Surfaces: Algorithm and Application. *New York Science Journal*, 4 (7): 21-28.

Nabiyev, V. (2005). *Yapay Zeka (Problemler-Yöntemler-Algoritma)*. Ankara: Seçkin Yayıncılık.

Nagar, A., Heragu, S.S. ve Haddock, J. (1996). A combined branch-and-bound and genetic algorithm based approach for a flowshop scheduling problem. *Annals of Operations Research*. 63 (3): 397 – 414.

Nagareshmi, S. ve Palagan, C. (2016). Analysis Of Segmenting Metro Trips Using Smart Card Data. *International Journal of Advanced Research in Management, Architecture, Technology*. 2 (6): 109-114.

Nasiboğlu, E., Kuvvetli, U., Ozkilcik, M., Eliyi, U. (2012). Origin-Destination Matrix Generation Using Smart Card Data: Case Study for Izmir. *IV International Conference “Problems of Cybernetics and Informatics” (PCI’2012)* (ss. 188-191). 12-14 Eylül.

Nasibov, E., Diker, A., ve Nasibov, E. (2016). A multi-criteria route planning model based on fuzzy preference degrees of stops. *Applied Soft Computing*. (49): 13-26.

Nasibov, E., Eliyi, U., Ertaç, M. ve Kuvvetli, Ü. (2013). Deadhead Trip Minimization in City Bus Transportation: A Real Life Application. *Promet- Traffic&Transportation*. 25 (2): 137-145.

Németh, M. ve Michal’çonok, G. (2016). Preparation and Cluster Analysis of Data from the Industrial Production Process for Failure Prediction. *Research Papers Faculty of Materials Science and Technology Slovak University of Technology*. 24 (39): 111-116.

Ngai, E., Xiu, L. ve Chau, D. (2009). Application of data mining techniques in customer relationship management: A literature review and classification. *Expert Systems with Applications*. 36: 2592-2602.

Nielsen, O.A. (2000). A stochastic transit assignment model considering differences in passengers utility functions. *Transportation Research Part B Methodological*. 34: 377–402.

Nielsen, O.A. (2004). Behavioral Responses to Road Pricing Schemes: Description of the Danish AKTA Experiment. *Journal Intelligent Transportation Systems*. 8 (4): 233–251.

Nielsen, O.A. ve Frederiksen, R.D. (2006). Optimisation of timetable-based, stochastic transit assignment models based on MSA. *Annual Operations Research*. 144 (1): 263–285.

Nihan, N.L. and Davis, G.A. (1989). Application of prediction error minimization and maximum likelihood to estimate intersection O-D matrices from traffic counts. *Transportation Science*. 23 (2): 77-90.

Nökel, K. ve Wekeck, S. (2009). Boarding and alighting in frequency-based transit assignment. *Transportation Research Record: Journal of Transportation Research Board*. 2111 (1): 60–67.

Nuzzolo, A., Crisalli, U., Rosati, L. (2012). A schedule-based assignment model with explicit capacity constraints for congested transit networks. *Transportation Research Part C: Emerging Technologies*. 20: 16–33.

Nuzzolo, A., Crisalli, U., Rosati, L., Comi, A. (2015). DYBUS2: a real-time mesoscopic transit modeling framework. *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC* (pp. 303–308). Canary Islands, Spain. September 15-18.

Nuzzolo, A., Russo, F. ve Crisalli, U. (2001). A doubly dynamic schedule-based assignment model for transit networks. *Transportation Science*. 35: 268–285.

Önder, E. ve Hasgöl, Ö. (2009). Yabancı Ziyaretçi Sayısının Tahmininde Box-Jenkins Modeli, Winters Yöntemi Ve Yapay Sinir Ağlarıyla Zaman Serisi Analizi. *İ.Ü. İşletme Fakültesi İşletme İktisadi Enstitüsü Yönetim Dergisi*. 20 (62): 62-83.

Özbay, E. (2007). *Finans Sektöründe Veri Madenciliği ile Dolandırıcılık Tespiti* (Yayınlanmamış Yüksek Lisans Tezi). Konya: Selçuk Üniversitesi Fen Bilimleri Enstitüsü.

Özbay, Ö. (2015). Veri Madenciliği Kavramı Ve Eğitimde Veri Madenciliği Uygulamaları. *INESJOURNAL - Uluslararası Eğitim Bilimleri Dergisi* , 2 (5), 262-272.

Özcan, C. (2014). *Veri Madenciliğinin Güvenlik Uygulama Alanları ve Veri Madenciliği ile Sahtekârlık Analizi* (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: İstanbul Bilgi Üniversitesi Sosyal Bilimler Enstitüsü.

Özçakır, F. ve Çamurcu, A. (2007). Birliktelik Kuralı Yöntemi İçin Bir Veri Madenciliği Yazılımı Tasarımı ve Uygulaması. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*. 6 (12): 21-37.

Özkan, Y. (2016). *Veri Madenciliği Yöntemleri*. İstanbul: Papatya Yayıncılık Eğitim.

Öztemel, E. (2012). *Yapay Sinir Ağları*. Ankara: Papatya Yayıncılık.

Öztemiz, F. ve Hamamcı, S. (2016). R Programlama Dili ve Apriori Algoritması Kullanılarak Market Sepet Analizi. *International Artifical Intelligence and Data Processing Symposium '16*, (s. 375-379). Malatya. 17 – 18 Eylül.

Öztürk, N. ve Yıldız, N. (2012). n<p Boyutlu Biyolojik Verilerde Farklı Kümeleme Yöntemlerinin Karşılaştırmalı Olarak İncelenmesi. *KSÜ Doğa Bilimleri Dergisi*. 15 (4): 26-36.

Özuysal, M., Çalışkanelli, S. ve Tanyel, S. (2016). Otobüs duraklarındaki yolcu iniş-biniş zamanları üzerine bir tartışma. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*. 22 (6): 460-467.

Özuysal, M., Deri, A., Kalpakcı, A. ve Çalışkanelli, P. (2015). Toplu Ulaşım Talebi Analizinde Akıllı Kart Verilerinden Yararlanılması. *11. Ulaştırma Kongresi*, (s. 425-436). İstanbul. 27 – 29 Mayıs.

Özüdoğru, A. ve Görener, A. (2015). Sağlık Sektöründe Talep Tahmini Üzerine Bir Uygulama. *İstanbul Ticaret Üniversitesi Sosyal Bilimleri Dergisi*. 14 (27): 37-53.

Packianather, M., Drake, P. ve Rowlands, H. (2000). Optimizing The Parameters Of Multilayered Feedforward Neural Networks Through Taguchi Design Of Experiments. *Quality And Reliability Engineering International*. 16 (6): 461-473.

Pakhira, M. ve De, R. (2007). Generational PipeLined Genetic Algorithm (PLGA) using Stochastic Selection. *International Journal Of Computer Systems Science and Engineering*. 1 (1): 75-88.

Paola, J. D. (1994) *Neural Network Classification Of Multispectral Imagery*. (Yayınlanmamış Yüksek Lisans Tezi). Arizona, USA: The University of Arizona.

Pelleg, D. ve Moore, A. (2000). X-means: Extending K-means with Efficient Estimation of the Number of Clusters. *In Proceedings of the 17th International Conference on Machine Learning (s. 727 – 734)*. Morgan Kaufmann: San Francisco.

Pelletier, M.-P., Trépanier, M. ve Morency, C. (2011). Smart Card Data Use in Public Transit: A Literature Review. *Transportation Research Part C*. 19(4): 557-568.

Peterson, A. (2007). *The origin-destination matrix estimation problem-analysis and computations*. (Yayınlanmamış Doktora Tezi). Norrköping, Sweden: Linköping University.

Pierce, B., Casas, J., ve Giaimo, G. (2003). Estimating Trip Rate Under- Reporting: Preliminary Results from the Ohio Travel Survey. *82nd Annual Meeting of the Transportation Research Board*, Washington, D. C. 12 – 16 Ocak.

Qin, F. (2014). Investigating the In-Vehicle Crowding Cost Functions for Public Transit Modes. *Hindawi Publishing Corporation Mathematical Problems in Engineering*, Volume 2014, Article ID 502708, 13 pages

Raissi, M., Perdikaris, P. ve Karniadakis, G.E. (2017). Physics Informed Deep Learning (Part I): Data-driven solutions of nonlinear partial differential equations. *Journal of Computational Physics*. 378: 686-707

Rajagopal, S. (2011). Customer Data Clustering Using Data Mining Technique. *International Journal of Database Management Systems (IJDMS)*. 3 (4): 1-11.

Rechenberg, I. (1973). Evolutionstrategie [Evolution Strategy]. Stuttgart: Frommann – Holzboog.

Rosenblat, F. (1958). The Perceptron: A Probabilistic Model For Information Storage And Organization. *Psychological Review*. 65 (6): 386-408.

Ross, D. A. (2002). *Master Math: Trigonometry*. Boston, USA: Course Technology Cengage Learning.

Rumelhart, D. E., Hinton, G. E. and Williams, R.J. (1986). Learning Internal Representation by Error Propagation. *Parallel Distributed Processing: Explorations in the Microstructure of Cognition (Yazan: D. Rumelhart ve J. McClelland)* (318-362). MIT Press.

Safi, H., Mesbah, M. ve Ferreira, L. (2014) Smartphone-assisted Travel Surveys: A Smart Way for Transport Planning. *Conference of Australian Institutes of Transport Research (CAITR)*, 32nd, Sydney, New South Wales, Australia. 17 – 18 Şubat.

Santos, A., McGuckin, N., Nakamoto, H. Y., Gray, D. ve Liss, S. (2011) *Summary of Travel Trends: 2009 National Household Travel Survey*, U.S. Department of Transportation and Federal Highway Administration.

Sarıman, G. (2011). Veri Madenciliğinde Kümeleme Teknikleri Üzerine Bir Çalışma: K-Means ve K-Medoids Kümeleme Algoritmalarının Karşılaştırılması. *Süleyman Demirel Üniversitesi, Fen Bilimleri Enstitüsü Dergisi*. 15 (3): 192-202.

Savasere, A., Omiecinsk, E. ve Navathe, S. (1995). An Eficient Algorithm for Mining Association Rules in Large Databases. *Proceedings of 20th International Conference on VLDB* (s. 432-444). San Francisco: Morgan Kaufmann Publishers. 12 – 15 Eylül.

Savaşçı, İ. ve Tatlıdil, R. (2006). Bankaların Kredi Kartı Pazarında Uyguladıkları CRM (Müşteri İlişkiler Yönetimi) Stratejisinin Müşteri Sadakatine Etkisi. *Ege Akademik Bakış Dergisi*. 6 (1): 62-73.

Schaffer, J.D., Caruana, R.A., Eshelman, L.J. ve Das, R. (1989). A Study Of Control Parameters Affecting On-Line Performance Of Genetic Algorithms for Function Optimization. *Proceedings of the Third International Conference on Genetic Algorithms*. Düzenleyen George Mason University. 4 – 7 Haziran 1989.

Schmaranzer, D., Braune, R. ve Doerner, K. F. (2018). Simulation-Based Headway Optimization For A Subway Network: A Performance Comparison Of Population-Based Algorithms. *Proceedings of the 2018 Winter Simulation Conference* (pp. 1957-1968). Gothenburg, Sweden. 09 – 12 Aralık.

Schmöcker, J.D., Fonzone, A., Shimamoto, H., Kurauchi, F., Bell, M.G.H. (2011). Frequency-based transit assignment considering seat capacities. *Transportation Research Part B: Methodological*. 45 (2): 392–408.

Selvi, H. Z. ve Çağlar, B. (2017). Çok Değişkenli Haritalama İçin Kümeleme Yöntemlerinin Kullanılması. *Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*. 6 (2): 415-429.

Sen, N. ve Nandi, M. (2012). Goal Programming, its Application in Management Sectors– Special Attention into Plantation Management: A Review. *International Journal of Scientific and Research Publications*. 2 (9): 1-6.

Servi, T. (2009). *Çok Değişkenli Karma Dağılım Modeline Dayalı Kümeleme Analizi*. (Yayınlanmamış Doktora Tezi). Adana: Çukurova Üniversitesi Fen Bilimleri Enstitüsü.

Shelfer, M., Procaccino, J.,D. (2002). Smart card evolution, *Communications of the ACM*. 45(7): 83-88.

Silahtaroğlu, G. (2016). *Veri Madenciliği (Kavram ve Algoritmalar)*. İstanbul: Papatya Yayıncılık Eğitim.

Simard, P.Y., Steinkraus, D. ve Platt, J.C. (2003). Best practices for convolutional neural networks applied to visual document analysis. *Proceedings of the Seventh International Conference on Document Analysis and Recognition*. 2: 958-062. Edinburgh, UK. 3 - 6 Ağustos.

Sinnott, R. W. (1984). Virtues of the Haversine. *Sky and Telescope*. 68 (2): 158-159.
Snaselova, P. ve Zboril, F. (2015). Genetic Algorithm using Theory of Chaos. *Procedia Computer Science*. 51: 316-325.

Soh, C.K. ve Yang, J. (1996). Fuzzy Controlled Genetic Algorithm Search for Shape Optimization. *Journal of Computing in Civil Engineering*. 10 (2): 143 – 150.

Specht, D. (1988). Probabilistic neural networks for classification, mapping, or associative memory. *IEEE 1988 International Conference on Neural Networks*, (s. 525-532). San Diego, CA, USA. 24-27 Haziran.

Specht, D. (1991). A General Regression Neural Network. *IEEE Transactions on Neural Networks*. 2 (6): 568-576.

Stauffer-Steinnocher, P. ve Fischer, M. M. (1997). Spectral Pattern Recognition by a Two-Layer Perceptron: Effects of Training Set Size. *Neuro-computation in remote sensing data analysis (Edt I. Kanellopoulos, G. Wilkinson, F. Roli, & J. Austin)* (105-116). London: Siproinger.

Stone, J. R., Ahmed, T. ve Nalevanko, A. (1999). *Small Urban and Rural Advanced Public Transportation Systems*, Federal Transit Administration and Advanced Public Transportation Systems Division.

Stopher, P. R., Prasad, C. ve Zhang, J. (2010). *Comparing GPS and Prompted Recall Data Records*. Working Paper ITLS-WP-10-24. Institute of Transport and Logistics Studies. University of Sydney, Australia.

Stopher, P., Clifford, E., Zhang, J. ve Fitzgerald, C. (2008). *Deducing Mode and Purpose from GPS Data*. Working Paper ITLS-WP-08-06. Institute of Transport and Logistics Studies. University of Sydney, Australia.

Stopher, P., Zhang, Y., Armoogum, J. ve Madre, J.-L. (2011). National Household Travel Surveys: The Case for Australia. *34th Australasian Transport Research Forum (ATRF)*. Adelaide, South Australia, Australia. 28 -30 Eylül.

Sun, X., Zhang, S., Dong, H. ve Zhu, H. (2013). Optimal train schedule with headway and passenger flow dynamic models. *IEEE ICIRT 2013 - Proc. IEEE Int. Conf. Intell. Rail Transp.* 1 (1): 307-312. Beijing, China. 30 Ağustos - 1 Eylül.

Sun, Y. ve Xiong, H. (2013). Real Coded Quantum Genetic Algorithm and its Application. *Journal of Engineering Science and Technology Review*. 6 (5): 25-32.

Cambridge Systematics, C. (2007) *National Rail Freight Infrastructure Capacity and Investment Study*. Cambridge, Massachusetts: Cambridge Systematics.

Şeker, A. (2013). *Süreç planlama ve çizelgeleme entegrasyonu için yapay sinir ağları ve genetik algoritmayı birleştiren hibrit bir yaklaşım*. (Yayınlanmamış Doktora Tezi). Ankara: Gazi Üniversitesi Fen Bilimleri Enstitüsü.

Şeker, S. (2014). Sosyal Ağlarda Akan Veri Madenciliği. *YBS Ansiklopedisi*. 1 (3): 21-27.

Şengöz, N. ve Özdemir, G. (2016). Temel Bileşenler Analizi Ve K-Ortalama Kümeleme Yönteminin Birlikte Kullanımı: Bir Örnek Uygulama. *Mehmet Akif Ersoy Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*. 8 (15): 85-94.

Şengür, D. (2013). *Öğrencilerin Akademik Başarılarının Veri Madenciliği Metotları İle Tahmini*. (Yayınlanmamış Yüksek Lisans Tezi). Elazığ: Fırat Üniversitesi Eğitim Bilimleri Enstitüsü.

Şimşek Gürsoy, U. (2009). *Veri Madenciliği ve Bilgi Keşfi*. Ankara: Pegem Yayıncılık.

Taha, H. (2007). *Yöneylem Araştırması (6.Basımdan Çeviri)*. (Çev. Ş. Baray ve Ş. Esnaf) İstanbul: Literatür Yayıncılık.

Taşkın, Ç. ve Emel, G. (2010). Veri Madenciliğinde Kümeleme Yaklaşımları Ve Kohonen Ağları İle Perakendecilik Sektöründe Bir Uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 15 (3): 395-409.

Tatlıldil, H. (1996). *Uygulamalı Çok Değişkenli İstatiksel Analiz*. Ankara: Akademi Matbaası.

Thao, S., Liu, D. ve Tang, A. (2019). Bridge Critical State Search by Using Quantum Genetic Firefly Algorithm. *Shock and Vibration*. 2019: 1 - 10.

Thierens, D. ve Goldberg, D. E. (1994). Convergence Models of Genetic Algorithm Selection Schemes. Y. S. Davidor (Dü.), *International Conference on Parallel Problem Solving From Nature: Parallel Problem Solving From Nature PPSN III*. (ss. 119-129). London: Springer-Verlag. 09 – 14 Ekim.

Tirachini, A.A. (2012). *Multimodal Pricing and the Optimal Design of Bus Services: New Elements and Extensions* (Yayınlanmamış Doktora Tezi). Institute of Transport and Logistics Studies The University of Sydney Business School The University of Sydney NSW 2006 Australia.

Ton, T. T. ve Hensher, D. A. (2002) A Spatial and Statistical Approach for Imputing Origin destination Matrices from Household Travel Survey Data: A Sydney Case Study. *25th Australasian Transport Research Forum*. Institute of Transport Studies, The University of Sydney. 2 – 4 Ekim.

Tosun, T. (2006). *Veri Madenciliği Teknikleriyle Kredi Kartlarında Müşteri Kaybetme Analizi*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.

Transportation Research Board's Travel Survey Methods Committee (2008) *The On-line Travel Survey Manual: A Dynamic Document for Transportation Professionals*, (ABJ40), Transportation Research Board.

TRB. (2006). *TCRP Report 113: Using Archived AVL-APC Data to Improve Transit Performance and Management*. Transportation Research Board.

Trépanier, M., Barj, S., Dufour, C. ve Poilpré, R. (2004). Examen des potentialités d'analyse des données d'un système de paiement par carte à puce en transport urbain [Examination of the potential use of smart card fare collection system in urban transportation], *Congrès annuel de 2004 de l'Association des transports du Canada*, Québec.

Trépanier, M., Chapleau, R. ve Tranchant, N. (2007). Trip Destination Estimation in a Transit Smart Card Automated Fare Collection System. *Journal of Intelligent Transportation Systems: Technology, Planning and Operations*. 11 (1): 1-14.

Trépanier, M., Morency, C. ve Agard, B. (2009). Calculation of Transit Performance Measures Using Smartcard Data. *Journal of Public Transportation*. 12 (1): 79-96.

Türkiye Belediyeler Birliği (2014). *Ulaşım Planlama Çalışmaları ve Ulaşım Ana Planı Hazırlama Kılavuzu*. <http://www.tbb.gov.tr/download.php?dosya=storage/catalogs/0360125001399467290.pdf&dosyaAdi=ulasim-plani-kilavuzu>, 10.05.2019.

Ulaş, M. (2001). *Market Basket Analysis For Data Mining*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Boğaziçi University, Computer Engineering.

Uludağ, N. (2010). *Bulanık Optimizasyon ve Doğrusal Hedef Programlama Yaklaşımları ile Otobüs Hatlarının Modellenmesi*. (Yayınlanmamış Doktora Tezi). Denizli: Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü.

Utsunomia, M., Attanucci, J. ve Wilson, N. (2006). Transit Smart Card Registration and Transaction Data to Improve Transit Planning. *Transportation Research Record: Journal of the Transportation Research Board*. 1971: 119-126.

Uyumaz, Ö. (2017). *Bankacılık Sektöründe Pazarlama Stratejilerinin Belirlenmesinde Sınıflandırma Ve Veri Madenciliği*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Beykent Üniversitesi, Fen Bilimleri Enstitüsü.

Van Oort, N., Brands, T. ve de Romph, E. (2015). Short Term Ridership Prediction In Public Transport By Processing Smart Card Data. *94 th Annual Meeting of the Transportation Research Board*. 2535: s. 105-111. Washington D.C. 11 – 15 Ocak.

Van Zuylen, H. ve Willumsen, L.G. (1980). The most likely trip matrix estimated from traffic counts, *Transportation Research, B*. 14: 281–293.

Varghese, V. ve Adhvaryu, B. (2016). Measuring overcrowding in Ahmedabad buses: costs and policy implications. *Transportation Research Procedia*. 17: 145 – 154.

Vatansever, M. (2008). *Görsel Veri Madenciliği Tekniklerinin Kümeleme Analizlerinde Kullanımı Ve Uygulanması*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü.

Victor, D.J. and Ponnuswamy, S. (2012). *Urban Transportation: Planning, Operation and Management*. New Delhi: Tata McGraw-Hill.

Vincenty, T. (1975). Direct and Inverse Solutions of Geodesics on the Ellipsoid with Application of Nested Equations. *Survey Review*. 23: 88-93.

Vuchic, R. V. (2005). *Urban Transit: Operations, Planning and Economics*. New Jersey: John Wiley and Sons Inc.

Wang, K.J., Wang, S.M. ve Chen, J.C. (2008). A resource portfolio planning model using sampling-based stochastic programming and genetic algorithm. *European Journal of Operational Research*. 184: 327 – 340.

Wang, L. Ve Jiao, L. (2000). A Novel Genetic Algorithm Based on Immunity. *IEEE International Symposium on Circuits and Systems. Emerging Technologies for the 21st Century. Proceedings*. 5: 385 – 388.

Wang, W., Attanucci, J.P. ve Wilson, N.H.M., (2011). Bus passenger origin-destination estimation and related analyses using Automated Data Collection Systems. *Journal of Public Transportation*. 14 (4): 131–150.

Whitehead, B.A. (1996). Genetic Evolution of Radial Basis Function Coverage Using Orthogonal Niches. *IEEE Transactions on Neural Networks*. 7 (6): 1525 – 1528.

Whitley, D. (1989). The Genitor algorithm and selection pressure: Why rank-based allocation of reproductive trials is best. *Proceedings of Third International Conference on Genetic Algorithms* (s. 116-121). Morgan Kaufmann.

Whitley, L.D. and Hanson, T. (1989). Optimizing Neural Networks Using FasterMore Accurate Genetic Search. *In Proceedings of the 3rd International Conference on Genetic Algorithms*. J. David Schaffer (Ed.) (pp. 370 – 374). San Francisco: Morgan Kaufmann Publishers Inc.

Widrow, B. ve Hoff, M. (1960). Adaptive Switching Circuits. *IRE WESCON Convention Record* , 96-104.

Widyawan, B., Prakasa, D., Putra, S. S., Kusumawardani, B. T. Y., Widhiyanto ve Habibie, F. (2017). Big data analytic for estimation of origin-destination matrix in bus rapid transit system. *Proceedings 3rd International Conference on Science and Technology- Computer (ICST)* (ss.165–170). Yogyakarta, Indonesia. 11 – 12 Haziran 2017.

Wolf, J., Guensler, R. ve Bachman, W. (2001) Elimination of the Travel Diary: Experiment to Derive Experiment to Derive Trip Purpose from Global Positioning System Travel Data. *Transportation Research Record: Journal of the Transportation Research Board*. 1768: 125-134.

Xu, L., Zhao, X. ve Tao, Y. (2014). Optimization of Train Headway in Moving Block Based on a Particle Swarm Optimization Algorithm. *13th International Conference on Control, Automation, Robotics & Vision* (pp. 931-935) . Singapore.

Yakut, E., Elmas, B. ve Yavuz, S. (2014). Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 19 (1): 139-157.

Yavuz, M. (2012). *Yapay Sinir Ağları İle Portföy Optimizasyonu*. (Yayınlanmamış Yüksek Lisans Tezi). Balıkesir: Balıkesir Üniversitesi, Fen Bilimleri Enstitüsü.

Yılmaz, S. (2009). *Yaşam Boyu Müşteri Değeri Modellemesi Üzerine Bir Örnek Uygulama*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.

Yiğit, M. ve Günel, T. (2016). Doğrusal Anten Dizisi Işıma Diyagramının Sentezi İçin Konveks-GenetikTaguchi Algoritmalarına Dayalı Yeni Bir Karma Optimizasyon Yaklaşım. *ELECO`2016 Elektrik - Elektronik - Bilgisayar Mühendisliği Sempozyumu Ve Fuarı Bildirileri* (s. 572-576), Bursa. 1 – 3 Aralık.

Yücenur, G., Demirel, Ç. ve N. (2011). Çok Depolu Araç Rotalama Problemlerinin Çözümü İçin Genetik Algoritma Ve Karınca Kolonisi Optimizasyonundan Oluşan Melez Algoritma Tasarımı. *Sigma: Mühendislik ve Fen Bilimleri Dergisi*. (29): 340-350.

Yücesoy, M. (2011). *Temizlik Kağıtları Sektöründe Yapay Sinir Ağları İle Talep Tahmini*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.

Zaki, M.J. ve Hsiao, C. (2002). CHARM: An Efficient Algorithm for Closed Itemset Mining. *2nd SIAM International Conference on Data Mining (SDM'02)* (s. 457-473), Arlington.

Zhang, Q. ve Benveniste, A. (1992). Wavelet networks. *IEEE Transactions Neural Networks*. 3: 889-898.

Zhang, S. ve Constantinides, A. (1992). Lagrange programming neural networks. *IEEE Trans. Circuits Syst. II, Analog Digit. Signal Process.* 39 (7): 441-452.

Zhao, J., Rahbee, A. ve Wilson, N. (2007). Estimating a rail passenger trip origin-destination matrix using automatic data collection systems. *Computer-Aided Civil and Infrastructure Engineering*. 22: 376–387.



EKLER

EK 1: Geliştirilen Yazılımdan Ekran Görüntüleri

Ana Form

“Aktarmalar”, “Günün İlk ve Son Binişleri”, “RAEM” ve “Son Durak İniş Durağı” düğmeleri temel algoritmalar çalışmaktadır. “Nihai OD Matrisi Oluştur” düğmesi belirlenen hat için başlangıç – varış matrisini hesaplar. “Hat Taleplerini Hesapla” düğmesi. Hat Nosu belirtilen hattın maksimum talep düzeyi hesaplanır. “Hat Talepleri İçin YSA’nı Eğit” düğmesi tahminleme için kullanılan yapay sinir ağı formunu açmaktadır. “Optimum Sefer Sıklıklarını Hesapla (Basit Yöntem)” ile geliştirdiğimiz optimizasyon programı çalışır ve çıktı verir. “Optimum Sefer Sıklıklarını Hesapla (G.A.)” düğmesi ile geliştirilen genetik algoritma tüm hatlar için optimum sefer sıklığını hesaplar ve çıktı verir.

HAT Planlama

Hat Planlama Yazılımı Sürüm 1.0

Hat No: 28021

Hat Sayısı: 343

Otobüs Sayısı: 1.724

Müşteri Sayısı: 1.372.342

Durak Sayısı: 6.469

Aktarmalar

Günün İlk ve Son Binişleri

Nihai OD Matrisi Oluştur

RAEM

Son Durak İniş Durağı

Özetle

Popülasyon Büyüklüğü: 10

Çaprazlama Oranı: 0,7

Mütasyon Oranı: 0,1

Mütasyon sayısı: 11

Nesil Sayısı: 500

Edt32

Toplam İlerleme

Hat Talepleri İçin YSA'nı Eğit

YSA2

Hat Taleplerini Hesapla

Optimum Sefer Sıklıklarını Hesapla (Basit Yöntem)

Optimum Sefer Sıklıklarını Hesapla (G.A.)

Gün: 0

Saat: 0

Talep: 593

d1+

d1-

dk+

dk-

d5+

d5-

Bekleme

Maliyet

KBDA

Başlama

Bitiş

Süre

Edt14

Sadece Negatif Sapmaları Dikkate Al

Beklemeleri Dikkate Al

Ağırlık Katsayıları

Maliyeti Dikkate Al

Kişi Başına Düşen Alanı Dikkate Al

Optimum Sefer Sıklığı

Optimum Z

Körük Otobüs Sayısı

Solo Otobüs Sayısı

Postif Sapma Ağırlık Katsayısı: 1


Negatif Sapma Ağırlık Katsayısı: 1000

Bekleme Süresi Ağırlık Katsayısı: 500

Maliyet Ağırlık Katsayısı: 5

Kişi Başına Düşen Alanı Ağırlık Katsayısı: 700

Yapay sinir ağı formunda kullanılan gizli katman ve çıktı katmanı aktivasyon fonksiyonları, iterasyon sayısı (epoch), nöron sayısı, başlangıç ağırlıkları için alt ve üst limitler ile öğrenme ve momentum katsayıları belirlenerek “Eğit” düğmesine basılır. Performans grafiği sağdaki gibi görünür. Çalışma bitince “Öğrenme Tamamlandı” şeklinde bir mesaj gelir.



EK 2: Otogar-Konak Hattı Hesaplanan Talep Düzeyleri

Gün Saat	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
06:00-06:59	60	64	23	92	82	85	104	82	59	23	116	104	112	92	91
07:00-07:59	115	150	57	319	301	324	282	279	192	62	312	316	332	332	311
08:00-08:59	122	178	107	287	278	273	270	306	226	88	272	283	275	302	280
09:00-09:59	154	136	102	221	239	268	244	202	173	90	162	175	235	205	215
10:00-10:59	197	190	118	271	210	177	198	184	136	118	200	157	236	185	162
11:00-11:59	170	196	135	310	221	246	268	274	178	154	225	191	257	224	231
12:00-12:59	133	260	210	248	201	251	219	234	230	229	192	221	228	249	198
13:00-13:59	169	283	260	231	212	249	267	184	257	247	249	222	201	208	188
14:00-14:59	196	253	235	364	260	283	221	220	157	223	255	267	241	219	257
15:00-15:59	191	199	210	348	251	326	294	263	266	231	352	215	272	294	312
16:00-16:59	163	159	187	356	405	311	304	325	214	167	342	284	285	238	384
17:00-17:59	155	84	162	201	184	233	197	230	195	148	225	203	230	167	157
18:00-18:59	144	114	93	194	222	186	260	202	154	150	249	215	190	204	217
19:00-19:59	144	114	105	216	158	174	243	220	122	93	171	175	216	219	233
20:00-20:59	88	75	78	116	160	158	108	112	102	84	118	103	100	133	94
21:00-21:59	65	45	80	57	97	90	71	64	50	53	60	79	79	57	75
22:00-22:59	49	36	43	74	79	77	49	59	86	72	90	60	55	82	76
23:00-23:59	37	39	45	36	42	29	52	45	32	38	28	34	18	37	36

EK 3: Aktarmalı Binişlerden Tespit Edilen İniş Duraklarına Örnekler

Hat	Biniş Durağı	X	Y	İniş Durağı	X	Y	Mesafe
OTOGAR-KONAK	Otogar	38,43094	27,21303	İskele	38,41988	27,12788	378,54 m
ÇINARTEPE-KONAK	Konak	38,41656	27,127				



Hat	Biniş Durağı	X	Y	İniş Durağı	X	Y	Mesafe
OTOGAR-KONAK	Şehitler	38,426137	27,1957	Otogar Kavşağı	38,42225	27,15043	0 m
KAVAKLIDERE-KEMER AKT.	Otogar Kavşağı	38,42225	27,15043				




Hat	Biniş Durağı	X	Y	İniş Durağı	X	Y	Mesafe
Otogar-Konak	Otogar Yeni	38,42902	27,21264	Havuzlu Kahve	38,42573	27,19785	0 m.
ALTINDAĞ-HALKAPINAR METRO	Havuzlu Kahve	38,42566	27,19835				



Aktarma Algoritmasında Reddedilen

Hat	Biniş Durağı	X	Y	İniş Durağı	X	Y	Mesafe
OTOGAR-KONAK	Kokluca Mezarlığı	38,42569	27,19075	Otogar Son Durak	38,42225	27,15043	3,08 km
DOĞANLAR-BORNOVA METRO	Bornova Metro	38,45864	27,21385				




EK 4: Sabah ve Akşam Binişlerinden İniş Durağı Tespitine Örnekler


Hat	Biniş Durağı	X	Y	İniş Durağı	X	Y	Mesafe
Otogar-Konak	Altındağ Belediyesi	38,42568	27,20075	Konak	38,41618	27,12635	0 m.
Otogar-Konak	Konak	38,41618	27,12635				



Hat	Biniş Durağı	X	Y	İniş Durağı	X	Y	Mesafe
AYAKKABICILAR SİTESİ- HALKAPINAR METRO	Çamdibi Esnaf Odası	38,43174	27,19357				1,10 km.
Otogar-Konak	Konak	38,41618	27,12635	Şehitler	38,42639	27,1944	




Hat	Biniş Durağı	X	Y	İniş Durağı	X	Y	Mesafe
Otogar-Konak	Kokluca Mezarlığı	38,42569	27,19075	İskele	38,41988	27,12788	422,39 m.
Otogar-Konak	Konak	38,41618	27,12635				



EK 5: Diğer'in Rastgele Atama Tahmin Yöntemine Göre Belirlenen İniş Duraklarına Örnek

KART_ID=613000000231915

Birniş Tipi	Hat	Gün	Saat	Birniş	x	Y	İniş	x	Y	Mesafe
Normal	EGEKENT AKT.-KONAK	1	12	Dedebaşı	38,47219	27,10768	Borsa	38,42445	27,13461	5,26 km
Aktarmalı	NARBEL-F.ALTAY AKT.	12	22	Fahrettin Altay Aktarmalı Merkezi	38,39913	27,06742	NULL			
Normal	NARBEL-F.ALTAY AKT.	13	7	Şahin	38,38461	27,013463	NULL			
Normal	NARBEL-F.ALTAY AKT.	13	7	Şahin	38,38461	27,013463	NULL			
Aktarmalı	ONUR MAH.-HALKAPINAR METRO 2	13	9	Çamlık	38,46705	27,16111	NULL			



KART_ID=109000000909411


Biniş Tipi	Hat	Gün	Saat	Biniş	x	Y	İniş	x	Y	Mesafe
Normal	EĞEKENT AKT.-KONAK	1	12	Dede başı	38,47219	27,10768	Tura n	38,46746	27,15028	8,24 km
Normal	TINAZTEPE-ŞİRİNYER AKT.	6	14	Buca Devlet Hastanesi	38,38579	27,16566	NULL			
Aktarmalı	BALÇOVA-KONAK	6	15	Konak	38,41618	27,12635	NULL			
Aktarmalı	TINAZTEPE-ŞİRİNYER AKT.	6	21	Şirinyer Aktarmalı	38,39053	27,14763	NULL			
Aktarmalı	TINAZTEPE-FALTAH AKT.	9	20	Şirinyer Karakol	38,392907	27,14832	NULL			
Aktarmalı	TINAZTEPE-ÜÇYOL METRO	10	13	Şirinyer Karakol	38,392907	27,14832	NULL			



EK 6: Hattın son durağının iniş durağı olarak atandığı örnekler

KART_ID=60901000119860

Birniş Tipi	Hat	Gün	Saat	Birniş	x	Y	İniş	x	Y	Mesafe
Normal	EGEKENT AKT - KONAK	1	14	Nikah Salonu	38,46667	27,16061	Karşıyaka Egekent Aktarma Merkezi	38,507161	27,046074	12,48 km
Normal	LİMONTEPE-KONAK	1	17	Bahribaba	38,4152	27,12775	NULL			



KART_ID=10000000698171

Biniş Tipi	Hat	Gün	Saat	Dakika	Biniş	x	Y	İniş	x	Y	Mesafe
Norm al	BOSTANLI İSKELE-KONAK	4	10	52	Karşıyaka İskele	38,45574	27,12211	NULL			
Aktarm alı	EGEKENT AKT.-KONAK	4	11	6	Liman	38,4403	27,14994	Montrö	38,4289	27,1414	4,53 km
Aktarmalı	EGEKENT AKT.-KONAK	4	13	15	Nikah Salonu	38,46667	27,16061	Karşıyaka Egekent Aktarma Merkezi	38,507161	27,046074	7,63 km
Aktarm alı	BAHRIYE ÜÇÖK-KARŞIYAKA İSKELE	4	13	25	Bahriye Üçök	38,46557	27,11545	NULL			
Norm al	BOSTANLI İSKELE-KONAK	9	11	6	Kasım an	38,45773	27,125282	NULL			
Aktarm alı	EGEKENT AKT.-KONAK	9	11	20	Liman	38,4403	27,14994	Montrö			

