

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ENDÜSTRİ MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

YAPAY SİNİR AĞLARI İLE TALEP TAHMİNLEME VE
DOĞRUSAL PROGRAMLAMA YAKLAŞIMI İLE DAĞITIM AĞI
OPTİMİZASYONU

MUHAMMED ARDA VURAL

KOCAELİ 2025

KOCAELİ ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

ENDÜSTRİ MÜHENDİSLİĞİ
ANABİLİM DALI

YÜKSEK LİSANS TEZİ

YAPAY SİNİR AĞLARI İLE TALEP TAHMİNLEME VE
DOĞRUSAL PROGRAMLAMA YAKLAŞIMI İLE DAĞITIM AĞI
OPTİMİZASYONU

MUHAMMED ARDA VURAL

Dr. Öğr. Üyesi Mehlika KOCABAŞ AKAY

Danışman, Kocaeli Üniversitesi

.....

Doç. Dr. Burcu ÖZCAN TÜRKKAN

Jüri Üyesi, Kocaeli Üniversitesi

.....

Dr. Öğr. Üyesi Ahmet CİHAN

Jüri Üyesi, Düzce Üniversitesi

.....

Tezin Savunulduğu Tarih: 04.02.2025

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ

Kocaeli Üniversitesi Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırladığım bu tez/proje çalışmada,

- Bu tezin/projenin bana ait, özgün bir çalışma olduğunu,
- Çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı,
- Bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi,
- Bu çalışmanın Kocaeli Üniversitesi'nin abone olduğu intihal yazılım programı kullanılarak Fen Bilimleri Enstitüsü'nün belirlemiş olduğu ölçütlere uygun olduğunu,
- Kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- Tezin/Projenin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez/proje çalışması olarak sunmadığımı,

beyan ederim.

- ☐ Bu tez/proje çalışmasının herhangi bir aşaması hiçbir kurum/kuruluş tarafından maddi/alt yapı desteği ile desteklenmemiştir.
- ☐ Bu tez/proje çalışması kapsamında üretilen veri ve bilgiler tarafından no'lu proje kapsamında maddi/alt yapı desteği alınarak gerçekleştirilmiştir.

Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

Muhammed Arda VURAL

YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI

Fen Bilimleri Enstitüsü tarafından onaylanan lisansüstü tezimin/projemin tamamını veya herhangi bir kısmını, basılı ve elektronik formatta arşivleme ve aşağıda belirtilen koşullarla kullanıma açma izninin Kocaeli Üniversitesi'ne verdiğimi beyan ederim. Bu izinle Üniversiteye verilen kullanım hakları dışındaki tüm fikri mülkiyet hakları bende kalacak, tezimin/projemin tamamının ya da bir bölümünün gelecekteki makale, kitap, tebliğ, lisans, patent gibi çalışmalarda kullanımı, danışmanımın isim hakkı saklı kalmak koşuluyla ve her iki tarafın bilgisi dâhilinde bana ait olacaktır.

Tezin/projenin kendi özgün çalışmam olduğunu, başkalarının haklarını ihlal etmediğimi ve tezimin/projenin tek yetkili sahibi olduğumu beyan ve taahhüt ederim. Tezimde yer alan telif hakkı bulunan ve sahiplerinden yazılı izin alınarak kullanılması zorunlu metinlerin yazılı izin alarak kullandığımı ve istenildiğinde suretlerini Üniversiteye teslim etmeyi taahhüt ederim.

Yükseköğretim kurulu tarafından yayınlanan **“Lisansüstü Tezlerin Elektronik Ortamda Toplanması, Düzenlenmesi ve Erişime Açılmasına İlişkin Yönerge”** kapsamında tezim aşağıda belirtilen koşullar haricinde YÖK Ulusal Tez Merkezi/ Kocaeli Üniversitesi Kütüphaneleri Açık Erişim Sisteminde erişime açılır.

- ☐ Enstitü yönetim kurulu kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 2 yıl ertelenmiştir.
- ☒ Enstitü yönetim kurulu gerekçeli kararı ile tezimin/projemin erişime açılması mezuniyet tarihinden itibaren 6 ay ertelenmiştir.
- ☐ Tezim/projem ile ilgili gizlilik kararı verilmemiştir.

Muhammed Arda VURAL

ÖNSÖZ VE TEŞEKKÜR

Yüksek lisans öğrenimim ve tez çalışma sürecimde, bilgi ve tecrübeleriyle beni yönlendiren, her türlü destek ve yardımıyla çalışmalarımı geliştirmeme büyük katkı sağlayan değerli hocam Dr. Öğr. Üyesi Mehlika Kocabaş Akay'a en içten dileklerimle teşekkür ederim.

Bu çalışmayı tamamlarken bana her an destek olan, varlığıyla güç veren sevgili eşim Zeynep Vural'a, koşulsuz sevgisi ve dualarıyla her zaman yanımda hissettiğim kıymetli annem Nuray Vural'a, birlikte üretmenin ve paylaşmanın kıymetini bana bir kez daha hatırlatan değerli çalışma arkadaşlarıma ve yolumu aydınlatan Kocaeli Üniversitesi'ne gönülden teşekkür ederim.

Şubat - 2025

Muhammed Arda VURAL



İÇİNDEKİLER

ETİK BEYAN VE ARAŞTIRMA FONU DESTEĞİ.....	i
YAYIMLAMA VE FİKRİ MÜLKİYET HAKLARI.....	ii
ÖNSÖZ VE TEŞEKKÜR.....	iii
İÇİNDEKİLER.....	iv
ŞEKİLLER DİZİNİ.....	vi
TABLOLAR DİZİNİ.....	viii
SİMGELER VE KISALTMALAR DİZİNİ.....	ix
ÖZET.....	x
ABSTRACT.....	xi
1. GİRİŞ.....	1
2. TALEP TAHMİNLEME.....	2
2.1. Talep Tahminleme Yöntemleri.....	3
2.1.1. Nitel Tahminleme Yöntemleri (Kalitatif).....	3
2.1.2. Nicel Tahminleme Yöntemleri (Kantitatif).....	4
2.2. Talep Tahminleme Üzerine Yapılan Akademik Çalışmalar ve Literatür Araştırması.....	5
3. İLERİ LOJİSTİK UYGULAMASI OLARAK DAĞITIM AĞI OPTİMİZASYONU VE KURULUŞ YERİ SEÇİMİ.....	7
3.1. Kuruluş Yeri Seçim Problemi ve Tarihçesi.....	7
3.2. Dağıtım Ağı Optimizasyonunda Kullanılan Yöntemler.....	8
3.3. Dağıtım Ağı Optimizasyonu-Literatür Araştırması.....	8
4. YAPAY SİNİR AĞLARI.....	12
4.1. Yapay Sinir Ağlarının Özellikleri.....	13
4.2. Yapay Sinir Ağları ve Öğrenme Teknikleri.....	14
4.3. Yapay Sinir Ağı Türleri.....	16
4.3.1. İleri Beslemeli Ağlar.....	16
4.3.2. Geri Beslemeli Ağlar.....	17
4.4. Yapay Sinir Ağı Tasarım Mimarisi.....	17
4.5. YSA Uygulama Alanları.....	18
4.6. YSA Avantajları ve Dezavantajları.....	20
4.6.1. Yapay Sinir Ağlarının Avantajları.....	21
4.6.2. Yapay Sinir Ağlarının Dezavantajları.....	21
4.7. Yapay Sinir Ağları Algoritma Akışı.....	22
5. HİBRİT MODEL KURGUSU.....	23
6. UYGULAMA.....	24
6.1. Mevcut Durum Değerlendirmesi.....	24
6.2. Matlab Üzerinde YSA İle Talep Tahminleme.....	25
6.3. Dağıtım Ağı Optimizasyonu.....	32
6.3.1. Optimizasyon Parametreleri.....	34
6.3.1.1. Amaç Fonksiyonu ve Tanımları.....	34
6.3.1.2. Model Kısıtları ve Değişkenleri.....	36
6.3.2. Matematiksel Model.....	39
6.3.3. Optimizasyon Modeli Maliyet Kalemleri Kurgusu.....	41
6.3.4. Mevcut Durum Dağıtım Ağı ve Maliyetleri.....	47
6.3.5. 2023 Mevcut Dağıtım Modelinin Optimize Edilmesi (Senaryo-1).....	49
6.3.6. 2023 Mevcut Dağıtım Modelinin Optimize Edilmesi (Senaryo-2).....	53

6.3.7. 2024 Yılı Tahmini Satışlarına Göre Optimizasyon.....	56
6.3.8. Tüm Modellerin Karşılaştırılması.....	58
6.3.9. 2024 Yılı Tahmini Satışlarına Göre Optimizasyon Senaryo-2.....	60
6.3.10. 2025 Yılı Tahmini Satışlarına Göre Optimizasyon Senaryo-1.....	63
6.3.11. 2025 Yılı Tahmini Satışlarına Göre Optimizasyon Senaryo-2.....	64
6.3.12. Tüm Modellerin Karşılaştırması.....	67
7. SONUÇ VE ÖNERİLER.....	74
KAYNAKLAR.....	76
KİŞİSEL YAYIN VE ESERLER.....	81
ÖZGEÇMİŞ.....	82



ŞEKİLLER DİZİNİ

Şekil 4.1. Yapay Sinir Ağ Katmanı.....	13
Şekil 4.2. Yapay Sinir Ağları Türleri.....	16
Şekil 5.1. Araştırma Yapılan Model Akışı.....	23
Şekil 6.1. Yıllara Göre Satış Toplamları.....	24
Şekil 6.2. İllere ve Aylara Göre Satış Rakamları.....	24
Şekil 6.3. 81 İlişin 12 Yıllık Satış Verisi.....	25
Şekil 6.4. Matlab Kodlama Ekranı.....	26
Şekil 6.5. Satış Verisinin Matlab'e Aktarılması.....	26
Şekil 6.6. Matlab Algoritma Sonucu.....	27
Şekil 6.7. Mean Squared Error Çıktısı.....	27
Şekil 6.8. Hata Histogramı.....	28
Şekil 6.9. Hedef ve Tahmin Uyumu.....	28
Şekil 6.10. İl ve Ay Bazlı İlk Tahmin Verileri.....	29
Şekil 6.11. Matlab Kodlama Görüntüsü.....	30
Şekil 6.12. Ankara İli Gerçekleşen ve Tahmini Satışlar.....	30
Şekil 6.13. İstanbul İli Gerçekleşen ve Tahmini Satışlar.....	30
Şekil 6.14. İzmir İli Gerçekleşen ve Tahmini Satışlar.....	31
Şekil 6.15. Tahmini Satışların Excel Görüntüsü.....	31
Şekil 6.16. Satış Verilerinin Elleçlenmesi.....	32
Şekil 6.17. Yıllık Bazda Gerçekleşen ve Tahmini Satış Tonajları.....	32
Şekil 6.18. Doğrusal Programlama Genel Görünümü.....	33
Şekil 6.19. 2016-2023 Fiili Kapanış ve 2024-2025 Satış Tahminleri.....	33
Şekil 6.20. Dağıtım Operasyonu Maliyet Kalemeleri.....	35
Şekil 6.21. İller Arası Mesafe Matrisi.....	35
Şekil 6.22. OpenSolver Model Detayları.....	36
Şekil 6.23. Kısıt Gösterimi.....	37
Şekil 6.24. İl Bazlı Kısıtların Gösterimi.....	37
Şekil 6.25. Network KM Dağıtım Kısıtı.....	38
Şekil 6.26. Dağıtım Karar Modeli.....	41
Şekil 6.27. Besleme Maliyet Model Kurgusu.....	42
Şekil 6.28. Dağıtım Kararı ve Maliyet Kurgusu.....	42
Şekil 6.29. Elleçleme Kararı ve Maliyet Kurgusu.....	43
Şekil 6.30. İşçilik Maliyetleri Kurgusu.....	44
Şekil 6.31. Depo Alan İhtiyacı ve Kira Maliyeti Kurgusu.....	45
Şekil 6.32. Endeksa Gayrimenkul Birim Kiraları.....	46
Şekil 6.33. İl Bazlı Depo Kira Maliyetleri.....	46
Şekil 6.34. Dağıtım Ağı Kararına Göre Toplam Maliyetler.....	47
Şekil 6.35. Mevcut Durum Bölgesel Depolar Dağıtım Haritası.....	48
Şekil 6.36. 2023 Mevcut Durumun Optimizasyon İçin Hazırlanması.....	49
Şekil 6.37. 2023 Optv1 OpenSolver Görüntüsü.....	50
Şekil 6.38. Kullanılan Çözücü Algoritması.....	51
Şekil 6.39. 2023 Senaryo-2 Optimizasyon Modeli.....	54
Şekil 6.40. 2024 Senaryo-2 Optimizasyon Modeli.....	61
Şekil 6.41. 2025 Senaryo-1 Optimizasyon Modeli.....	63
Şekil 6.42. 2025 Senaryo-2 Optimizasyon Modeli.....	65
Şekil 6.43. 2023 Mevcut Durum Dağıtım Ağı Haritası.....	71

Şekil 6.44. 2023 Optimizasyon v1 Dağıtım Ağı Haritası.....	71
Şekil 6.45. 2024 Optimizasyon v1 Dağıtım Ağı Haritası.....	72
Şekil 6.46. 2025 Optimizasyon v1 Dağıtım Ağı Haritası.....	72



TABLÖLAR DİZİNİ

Tablo 6.1.	2023 Mevcut Durum Maliyetleri.....	49
Tablo 6.2.	Mevcut Durum ve 2023 Optimizasyon Sonucu Maliyetleri.....	51
Tablo 6.3.	2023 Optv1 Sonucu Depolar Listesi.....	53
Tablo 6.4.	Mevcut Durum ve 23 Optv1, 23 Optv2 Mali Karşılaştırmaları.....	54
Tablo 6.5.	Optv1 ve Optv2 Depolar Listesi.....	56
Tablo 6.6.	2023 Optv1 ve 2024 Optv2 Maliyet Karşılaştırması.....	57
Tablo 6.7.	2024 Optv1 Depolar Listesi.....	58
Tablo 6.8.	2023 ve 2024 Tüm Modellerin Karşılaştırması.....	59
Tablo 6.9.	2024 Optv1 ve 2024 Optv2 Karşılaştırması.....	61
Tablo 6.10.	2024 Optv1 ve Optv2 Depolar Listesi.....	62
Tablo 6.11.	2025 Optv1 Maliyet Analizi Tablosu.....	64
Tablo 6.12.	2025 Optv1 ve 2025 Optv2 Karşılaştırması.....	65
Tablo 6.13.	2025 Optv1 ve 2025 Optv2 Depolar Listesi.....	66
Tablo 6.14.	2023 Mevcut Durum, 2024-2025 Optimizasyon Sonuçlarının Mali Karşılaştırması.....	67
Tablo 6.15.	2023 Mevcut Durum, 2024 ve 2025 Optimum Depo Yerleşimine Göre Depoların Çalışma Süreleri.....	70

SİMGELER VE KISALTMALAR DİZİNİ

Kısaltmalar

ANN	: Artificial Neural Networks (Yapay Sinir Ağları)
ARP	: Araç Rotalama Problemi
AUARP	: Açık Uçlu Araç Rotalama Problemi
BNN	: Bayesian Sinir Ağları
ÇDARP	: Çok Depolu Araç Rotalama Problemi
DARP	: Dinamik Araç Rotalama Problemi
DNO	: Dağıtım Ağı Optimizasyonu (Distribution Network Optimization)
EUR	: Euro
FLS	: Facility Location Selection (Kuruluş Yeri Seçimi)
GAP	: Genelleştirilmiş Atama Problemi
LP	: Linear Programming (Doğrusal Programlama)
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hata
MIP	: Mixed-Integer Programming (Karışık Tam Sayılı Programlama)
MSE	: Hata Kareleri Ortalaması
RMSE	: Hata Kareleri Ortalamasının Kökü
SANN	: Yığılmış Sinir Ağları
SCM	: Supply Chain Management (Tedarik Zinciri Yönetimi)
TGE	: Tüketici Güven Endeksi
TL	: Türk Lirası
USD	: Dolar
YSA	: Yapay Sinir Ağları

YAPAY SİNİR AĞLARI İLE TALEP TAHMİNLEME VE DOĞRUSAL PROGRAMLAMA YAKLAŞIMI İLE DAĞITIM AĞI OPTİMİZASYONU

ÖZET

Günümüz rekabet ortamında, müşteri taleplerini tam zamanında ve doğru şekilde karşılamak, şirketler için kritik bir rekabet avantajı haline gelmiştir. Enflasyonist pazar koşullarında, ürün ve hizmetin zamanında teslim edilmesi, kimi zaman fiyat faktöründen daha öncelikli hale gelerek müşteri memnuniyetinin en belirleyici unsurlarından biri olmuştur. Bu doğrultuda, müşteri taleplerinin önceden tahmin edilmesi ve optimum lojistik planlama ile karşılanması, şirketlerin sürdürülebilir büyüme stratejileri açısından büyük önem arz etmektedir.

Özellikle pandemi sonrası değişen tüketici davranışları, tedarik zinciri yönetiminde esneklik, hız ve verimlilik gerekliliğini artırmış, bu durum üretim, perakende ve lojistik sektörlerinde daha etkin dağıtım modellerinin geliştirilmesini zorunlu hale getirmiştir. Artan beklentiler ve rekabet koşulları, şirketleri maliyet etkinliği sağlayan, aynı zamanda yüksek servis seviyelerini koruyabilen dağıtım ağlarını kurmaya yönlendirmiştir. Bu kapsamda, doğru yerleşim yeri seçimi ve dağıtım ağı optimizasyonu, tedarik zinciri süreçlerinde maliyet ve operasyonel verimliliği artırmada temel bir unsur olarak karşımıza çıkmaktadır.

Bu çalışmada, müşteri taleplerini önceden tahmin etmek için Yapay Sinir Ağları (YSA) ile talep tahminleme modelleri incelenmiş, ardından bu tahminlerin lojistik operasyonları destekleyici bir optimizasyon modeli ile nasıl entegre edilebileceği araştırılmıştır. Kuruluş yeri seçimi ve dağıtım ağı optimizasyonu, doğrusal programlama yaklaşımıyla ele alınmış, talep tahminleme sürecinin sağladığı verilerin optimizasyon modeli ile nasıl hibrit bir yapıya dönüştürülebileceği detaylandırılmıştır. Çalışmanın sonucunda, hem talep tahmini doğruluğunu artıran hem de dağıtım süreçlerini maliyet ve performans açısından optimize eden bütünsel bir yaklaşım önerilmektedir.

Anahtar Kelimeler: Dağıtım Ağı Optimizasyonu, Karışık Tam Sayılı Programlama, Kuruluş Yeri Seçimi, Talep Tahminleme, Yapay Sinir Ağları.

DEMAND FORECASTING WITH ARTIFICIAL NEURAL NETWORKS AND DISTRIBUTION NETWORK OPTIMIZATION WITH A LINEAR PROGRAMMING APPROACH

ABSTRACT

In today's competitive business environment, meeting customer demands accurately and on time has become a crucial competitive advantage for companies. Under inflationary market conditions, the timely delivery of products and services has sometimes taken precedence over pricing, emerging as one of the most critical factors in customer satisfaction. In this context, forecasting customer demand in advance and fulfilling it through optimal logistics planning has become vital for the sustainable growth strategies of businesses.

Especially in the post-pandemic era, shifting consumer behavior has increased the need for flexibility, speed, and efficiency in supply chain management. This necessity has driven companies in manufacturing, retail, and logistics to develop more effective distribution models. Rising customer expectations and intensified competition have compelled businesses to establish cost-efficient distribution networks that also maintain high service levels. In this regard, optimal facility location selection and distribution network optimization play a fundamental role in improving cost-effectiveness and operational efficiency in supply chain processes.

This study examines Artificial Neural Networks (ANNs) for demand forecasting, followed by an investigation into how these forecasts can be integrated into an optimization model to support logistics operations. The facility location selection and distribution network optimization are approached using linear programming methods, and the study elaborates on how data derived from demand forecasting can be transformed into a hybrid optimization framework. As a result, a comprehensive approach is proposed that enhances demand forecasting accuracy while also optimizing distribution processes in terms of cost and performance.

Keywords: Distribution Network Optimization, Mixed-Integer Programming, Facility Location Selection, Demand Forecasting, Artificial Neural Networks.

1. GİRİŞ

Günümüzün hızla değişen ve giderek sertleşen rekabet ortamı, işletmeleri maliyetlerini daha etkin yönetmeye yönlendirmekte, rekabet avantajı elde etmek için verimlilik odaklı stratejiler geliştirmeye zorlamaktadır. Müşteri beklentilerini en ekonomik ve etkin şekilde karşılamak, ticari başarı açısından kritik bir faktör haline gelmiş ve bu durum işletmeleri Yalın Üretim, Yalın Lojistik gibi verimlilik esaslı yaklaşımları benimsemeye teşvik etmiştir. Lojistik maliyetleri, işletmelerin toplam maliyet yapısında önemli bir yer tutmakta olup, stok tutma, taşıma ve depolama maliyetleri lojistik harcamalar içinde en büyük paya sahiptir.

Son yıllarda e-ticaretin küresel ve yerel ölçekte hızla büyümesi, buna ek olarak COVID-19 pandemisi nedeniyle değişen tüketici alışkanlıkları, lojistik sektöründe beklenmedik değişimlere yol açmıştır. Tüketicilerin geniş ürün yelpazesine erişim talepleri ve hızlı teslimat beklentileri, depolama ihtiyacını artırarak lojistik yönetimde yeni optimizasyon gereksinimlerini gündeme getirmiştir. Özellikle pandemi sürecinde yaşanan tedarik zinciri aksaklıkları, hızlı servis beklentisini artırmış ve taşıma maliyetlerini stratejik bir maliyet kalemi haline getirmiştir.

Bu çalışmada, müşteri taleplerinin geleceğe yönelik nasıl tahmin edilebileceği incelenmiş, yapay zeka destekli tahminleme modelleri araştırılmış ve bu modellerin lojistik operasyonları destekleyici rolü ortaya konulmuştur. Aynı zamanda, ileri lojistik uygulamaları ve dağıtım ağı optimizasyonu konularında literatür taraması yapılmış, mevcut modellerin güçlü ve zayıf yönleri değerlendirilmiştir.

Çalışmanın uygulama bölümünde, sektöründe uzun yıllardır lider konumda bulunan bir şirketin geçmiş satış verileri baz alınarak, Türkiye çapında satış tahmini gerçekleştirilmesi hedeflenmiştir. Tahminleme sonuçları, lojistik dağıtım süreçlerinin en hızlı ve en ekonomik şekilde planlanmasını sağlayacak optimizasyon modeli için temel girdi olarak kullanılacaktır. Dağıtım ağı optimizasyonu, doğrusal programlama ve karışık tam sayılı programlama yaklaşımlarıyla ele alınarak, depo yerleşim seçimi ve dağıtım yapısının optimum şekilde tasarlanması amaçlanmaktadır. Bu sayede, işletmelerin lojistik maliyetlerini minimize eden, ancak müşteri memnuniyetini en üst düzeyde tutan bir dağıtım modeli geliştirilmesi hedeflenmektedir.

2. TALEP TAHMİNLEME

Talep, kısaca tüketicilerin herhangi bir ürün veya hizmeti satın alma isteği olarak tanımlanır. Tüketicilerin satın alma gücüne sahip olması, talebin oluşabilmesi için en önemli şarttır. Talebe etki eden tüm faktörler; tüketicinin satın alma gücü, ürün veya hizmetin fiyatı, tüketici alışkanlıkları, çevresel etmenler ve ihtiyacın gereklilik durumu şeklinde sıralanabilir (Zontul, 2017).

Tahmin, en basit anlamıyla, geçmiş verilere dayanarak geleceğe ilişkin öngörülerde bulunma sürecidir (Karahana, 2016).

Talep tahmini, tüketicilerin gelecekte ihtiyaç duyacakları mal ve hizmet miktarını tahmin etme sürecidir. Bu tahminler, işletmelerin üretim seviyelerini planlamasında önemli bir rol oynar. Üretilcek ürün çeşitleri, tüketicilerin bu ürünlere yönelik talep miktarları ve talebin hangi zaman aralıklarında gerçekleşeceğine dair olasılıklar, talep tahmini ile analiz edilir (Meydan, 2007).

Talep tahmini süreçlerinde üç temel yöntem kullanılmaktadır: kantitatif, kalitatif ve yapay zeka tabanlı yöntemler. Son yıllarda teknolojinin hızlı gelişimiyle birlikte yapay zeka tabanlı yöntemler de bu alanda yaygın bir şekilde kullanılmaya başlanmıştır. Kalitatif yöntemler, daha çok kişisel çıkarımlara, uzman görüşlerine ve deneyimlere dayanırken, kantitatif yöntemler istatistiksel ve matematiksel analizlere dayalıdır. Bu yöntemler, geçmiş verilere ilişkin detaylı analizler yaparak gelecekteki talepleri tahmin etmeyi mümkün kılar (Kılıç, 2015).

Talep tahmini, Üretim Planlama ve Kontrol Sistemi açısından kritik bir öneme sahiptir. Gelecekte ortaya çıkabilecek durumların kesin olarak öngörülememesi, planlama süreçlerini etkili bir şekilde yürütmenin önündeki en büyük zorluklardan biridir. Bu nedenle, ileriye dönük belirsizlikleri azaltmaya yönelik her çalışma, planlama işlevlerinin başarıyla yerine getirilmesine önemli katkılar sağlayacaktır. Bu belirsizliklerin üstesinden gelmek için çeşitli tahminleme yöntemlerinden yararlanılmaktadır (Winston, 1994).

Tahmin sonuçları ile gerçekleşen talep değerleri arasındaki farkın büyümesi, tahmin hatalarının artmasına ve bir dizi olumsuzluğa yol açabilir. Bu tür hatalar, atıl kapasite oluşumu, tüketici taleplerinin karşılanamaması ve ürün stoklarının gereksiz yere

birikmesi gibi sorunlara neden olabilir. Bu durum, işletme maliyetlerinin yükselmesine de sebep olur. Bu nedenle, üretim sistemlerinin tasarımı, planlanması ve işletilmesiyle ilgili stratejik kararlar alınırken doğru ve güvenilir tahmin verilerinin kullanılması, işletme başarısı için temel bir gereklilik olarak kabul edilmektedir (Meydan, 2007).

Talep tahmini, işletmelerin faaliyetlerini düzenli bir şekilde kontrol altında tutabilmesi ve daha iyi kararlar alabilmesi için kısa, orta ve uzun vadeli çalışmaların yapılmasını gerektirir. Bunun yanı sıra, talep tahmini işletmenin faaliyet alanına bağlı olarak üretim miktar tahmini, pazar analizi, satış tahmini ve finansal tahminler gibi kategorilere ayrılarak sınıflandırılabilir (Winston, 1994).

2.1. Talep Tahminleme Yöntemleri

Talep tahmini, belirli bir yöntemle sınırlı değildir. Bu süreçteki temel hedef, farklı talep yapılarına uygun tekniklerden yararlanarak mevcut verilerden doğru ve faydalı öngörüler geliştirmektir. İşletmeler, ihtiyaçlarına ve durumlarına bağlı olarak birden fazla yöntemi bir arada kullanabilmektedir. Genel olarak talep tahmini yöntemleri, nitel ve nicel yaklaşımlar olmak üzere iki ana kategoriye ayrılmaktadır (Krajewski, 2013).

Son yıllarda talep tahmini araştırmalarında, karmaşık problemlerin çözümü için yapay zeka tabanlı yöntemlerin kullanımına başlanmıştır. Literatürde bu yöntemler farklı şekillerde sınıflandırılrsa da, genel olarak iki ana grupta ele alınmaktadır (Karabacak ve Uzundumlu, 2020).

Nicel yöntemlerin temel girdisi, farklı zaman dilimlerinde toplanan verilerdir. Bu yöntemlerin başarısı, verilerin doğru ve etkili bir şekilde analiz edilmesine dayanır. Öte yandan, nitel yöntemler konu uzmanlarının bilgi ve deneyimlerinden yararlanarak alanın gelecekteki yönelimlerine ve ortaya çıkabilecek ihtiyaçların doğasına odaklanır (Söylemez, 2020).

2.1.1. Nitel Tahminleme Yöntemleri (Kalitatif)

Bu yöntemlerde bilgi işleme süreci uzmanlarca yürütülür. Nitel yöntemler, öznel yargılara dayandığı ve tekrar edilebilirliği sınırlı olduğu için tartışmalı sonuçlar üretebilir. Ancak düşük maliyetli olmaları ve özel istatistiksel bilgi gerektirmemeleri önemli

avantajlarıdır. Dezavantajları arasında, panelistlerin deneyimsizliği, kişisel görüşlerini yansıtmaya eğilimi ve gelecek beklentilerinin tahmini etkileyebilmesi yer alır (Yabar ve Aydın, 2020).

Nitel tahmin yöntemlerinde, tahmini gerçekleştirecek kişinin işletmedeki deneyimi ve konuya olan uzmanlığı büyük önem taşımaktadır. Tahmin süreci genellikle duygusal verilere ve kişisel görüşlere dayandığından, sonuçların doğruluğunu yorumlamak oldukça zordur. Nitel yöntemler kapsamında kullanılabilecek bazı teknikler şunlardır:

- Uzman Görüşü: Konuyla ilgili uzmanların bilgi ve deneyimlerinden faydalanarak tahminlerin yapılması.
- Delphi Tekniği: Uzmanların anonim bir şekilde fikirlerini paylaşması ve birden fazla turda görüşlerin birleştirilmesi yoluyla tahmin sürecinin gerçekleştirilmesi.
- Anket Yöntemi: Geniş katılımcı gruplarından bilgi toplamak için anketler kullanılarak tahminlerin yapılması.
- Senaryo Analizi: Gelecekteki olası durumların farklı senaryolar üzerinden değerlendirilerek tahminlerin şekillendirilmesi.
- Satış Gücü Birleşimi: Satış ekibinin pazar bilgisi ve öngörülerinin bir araya getirilmesi yoluyla tahmin yapılması (Çoban, 2019).

2.1.2. Nicel Tahminleme Yöntemleri (Kantitatif)

Niceliksel tahmin yöntemleri, matematiksel ve istatistiksel formüller kullanılarak uygulanır. Bu yöntemler, her biri kendine özgü özelliklere sahip çeşitli tekniklerden oluşan bir yaklaşımı temsil etmektedir (Tomar ve diğ, 2023). Bu tahmin teknikleri, geçmiş verilerden çıkarımlar yapmayı esas alır. Tahmin edilmesi gereken değerlerin yanı sıra, ilgili değişkenlerin belirlenmesini içeren niceliksel tahmin yöntemleri, değişkenler arasındaki ilişkileri istatistiksel modeller kullanarak saptar (Bhattacharya, 1997).

Zaman Serisi Analizi, İlişkiye Dayalı Yöntemler (Regreson), Mekanik Tahmin Yöntemi, Hareketli Ortalamalar Yöntemi, Üstel Düzleştirme Yöntemleri ve Box-Jenkins Yöntemi olarak sıralanabilir (Çuhadar ve Kayacan, 2005).

2.2. Talep Tahminleme Üzerine Yapılan Akademik Çalışmalar ve Literatür Araştırması

Talep tahmini üzerine yapılan literatür araştırmaları, son yıllarda yerli ve yabancı kaynaklarda bu konuda çeşitli çalışmaların yürütüldüğünü ve farklı çözüm yöntemlerinin uygulandığını ortaya koymaktadır. Genel bir inceleme yapıldığında, çalışmaların şu şekilde özetlenebileceği görülmektedir;

Serttaş (2011), “Türkiye’de Perakende Sektöründe Talebi Etkileyen Etmenler ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması” başlıklı tez çalışmasında, bir süpermarketin günlük ve mevsimsel satışlarını Yapay Sinir Ağları modeli kullanarak tahminlemeye çalışmıştır.

Yücesoy (2011), “Temizlik Kağıtları Sektöründe Yapay Sinir Ağları İle Talep Tahmini” adlı çalışmasında, Türkiye’deki temizlik kağıdı sektöründe parametrelere dayalı bir talep tahmini modeli geliştirmiştir. Modelin oluşturulması ve test edilmesinin ardından, geleceğe yönelik değerlendirmeler yapmış, her bir parametrenin talep üzerindeki etkisini analiz etmiş ve sonuçları diğer talep tahmin yöntemleriyle karşılaştırmıştır.

Solak (2013), “Türkiye’nin Toplam Petrol Talebi ve Ulaştırma Sektörü Petrol Talebinin ARIMA Modeli İle Tahmin Edilmesi” başlıklı çalışmasında, 2012-2020 dönemine ilişkin petrol talebini Otoregresif Entegre Hareketli Ortalama (ARIMA) modeliyle tahmin etmiştir. Çalışmanın çıktıları, Türkiye’nin petrol tüketimi açısından gelecekte ulaşacağı seviyeler için projeksiyonlar sunmuştur.

Sarı (2016), “Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması” başlıklı çalışmasında, motor yataklarının satış talep tahminini gerçekleştirmeyi hedeflemiştir. Çalışmada, motor satış talebini etkileyen faktörler arasında dolar kuru, GSYH endeksi, ihracat endeksi, faiz oranları, ÜFE ve TÜFE gibi değişkenlerin önemli olduğu belirlenmiştir. Yapay Sinir Ağları ile elde edilen tahmin sonuçları, Regresyon Analizi ve Zaman Serileri Analizi sonuçlarıyla karşılaştırılmış ve Yapay Sinir Ağları ile gerçeğe daha yakın tahminler elde edildiği ortaya konmuştur.

Efendigil ve Eminler (2017), “Havacılık Sektöründe Talep Tahmininin Önemi: Yolcu Talebi Üzerine Bir Tahmin Modeli” başlıklı çalışmalarında, yapay zeka tekniklerini

ekonometrik modellerle karşılaştırmıştır. Çalışmada, adaptif sinirsel bulanık çıkarım sistemi, yapay sinir ağları ve regresyon analizi teknikleri kullanılmış ve havacılık sektöründe yolcu talebi tahmini için en güvenilir modelin yapay sinir ağları olduğu sonucuna ulaşılmıştır.

Ulucan ve Kızılırmak (2018), “Konaklama İşletmelerinde Talep Tahmin Yöntemleri: Yapay Sinir Ağları İle İlgili Bir Araştırma” başlıklı çalışmalarında, İstanbul’daki bir beş yıldızlı otelin 2013-2016 yılları arasında satılan oda sayıları üzerine Yapay Sinir Ağları modeli kurarak, 2017-2018 sezonu için talep tahminleri yapmışlardır. Yaptıkları test ve karşılaştırmalar sonucunda, Yapay Sinir Ağları modelinin gerçeğe en yakın sonuçları ürettiğini ve geleneksel yöntemlere güçlü bir alternatif olabileceğini ifade etmişlerdir.

Chen ve arkadaşları (2009), 1996-2007 yılları arasında Tayvan’a havayolu ile gelen turist sayıları üzerine bir çalışma yapmış ve bu veri seti üzerinde Holt-Winters yöntemi, Mevsimsel ARIMA modeli ve Gri Tahminleme modellerini kullanarak analizler gerçekleştirmiştir. Araştırma sonuçlarına göre, mevsimsel etkiler dikkate alındığında, Mevsimsel ARIMA modelinin Tayvan’a gelen turist sayılarının tahmini için en uygun yöntem olduğu sonucuna ulaşılmıştır.

Constantino ve arkadaşları (2016), Ocak 2004 ile Aralık 2013 arasında ABD, Güney Afrika, Mozambik, Portekiz ve Birleşik Krallık’tan gelen turist sayıları verilerini, GSYH, TÜFE ve döviz kurları gibi değişkenlerle birlikte Yapay Sinir Ağları modelinde test etmişlerdir. Çalışma sonucunda, %6,5 MAPE oranı ile Yapay Sinir Ağları modelinin talep tahmini için güvenilir bir yöntem olduğu belirlenmiştir.

Huber ve Stuckenschmidt (2020), perakendecilik sektöründe çeşitli ürün kategorilerine yönelik talep tahmini yapmayı amaçladıkları çalışmalarında, model girdisi olarak üretim ve sipariş verilerini kullanmışlardır. Çalışmada Yapay Sinir Ağları ve Gradyan Destekli Karar Ağacı yöntemlerini uygulamışlardır. Sonuçlar, makine öğrenimi yöntemlerinin üstünlüğünü ortaya koyarken, sınıflandırma yaklaşımlarının regresyon tabanlı modellere kıyasla daha iyi performans gösterdiğini göstermiştir. Ayrıca, makine öğrenimi yöntemlerinin perakende sektöründe sıkça karşılaşılan büyük ölçekli talep tahmini senaryolarında daha başarılı sonuçlar verdiği sonucuna ulaşılmıştır.

3. İLERİ LOJİSTİK UYGULAMASI OLARAK DAĞITIM AĞI OPTİMİZASYONU VE KURULUŞ YERİ SEÇİMİ

Kuruluş yeri seçimi, karar mercileri tarafından bir işletmenin, depo yerinin vb. tesislerin nerede kurulacağına karar verilmesi çalışmaları olarak özetlenebilir. İşletmeler için stratejik öneme sahip olan hammadde, üretim, depolama, dağıtım gibi temel fonksiyonları karşılayabilen ve bu fonksiyonları en düşük maliyetle verimlilik artışı sağlayabilen yer, en uygun yerleşim yeri olarak tanımlanmaktadır. Bu problem tesis yerleştirme/tesis yeri seçimi/kuruluş yeri seçimi problemi olarak ele alınmaktadır. Tesis yerleştirme problemi ayrıca yöneylem araştırmacılarının da ilgi alanına girmekte ve daha çok dağıtım maliyetlerinin minimize edilmesi şeklinde çalışılmaktadır. Kuruluş yeri seçiminde genel amaç çoğunlukla kurulacak tesis ile talep noktaları arasındaki mesafeyi minimize ederek toplam maliyeti düşürmek ve işletmeye ait karlılığı artırmaktır (Abdolvahitoğlu, 2021).

Tesis yerleşim yerinin karar verilmesini etkileyen birçok etken bulunmaktadır. Bu etkenler; finansal durum, hammadde ve stratejik kaynaklara yakınlık, pazara ve müşteriye yakınlık, yerleşim yerinin altyapısı, coğrafi konum, ulaşım imkanları, su, elektrik, enerji gibi temel unsurların bulunabilir olması, rakip işletmeler arasındaki rekabet ve mevcut tesislerinin sayısı, arazi satınalma veya kiralamaya ilişkin maliyetler, bölgedeki işgücü temini, tedarikçilere olan uzaklık, işletmeye ait diğer tesislere olan uzaklık, bölgedeki mevcut yapıların yeni tesisin kurulmasına ilişkin tavırları, vergi ve yasal maliyetler, bölgenin güvenlik yapısı vb. şeklinde sıralanabilir (Durak ve Yıldız, 2015).

3.1. Kuruluş Yeri Seçim Problemi ve Tarihçesi

Tesis yeri seçim problemine minimum maliyet ile ekonomik bir çözüm geliştiren ilk kişi Alman ekonomi profesörü Johann Heinrich von Thünen'dir. Bundan sonraki ilk çalışmalar ise 1885 yılında Alman matematikçi ve ekonomist Carl Wilhelm Friedrich Launhardt tarafından yapılmış olup farklı lokasyonların maliyet ve talep unsurlarını karşılaştırıp tesis yeri seçimi kararından taşıma maliyetlerinin etkisini ortaya çıkarmıştır. Alman ekonomist ve sosyolojist Alfred Weber ise yayınladığı *Über den Standort der Industrie* (Endüstrilerin Konumu Teorisi) adlı çalışmasında endüstride yer seçimi ile ilgili ilk teoriyi geliştirmiştir (Üstüner, 2019).

Alfred Weber 1909 yılında satıcılar ile müşteriler arasındaki uzaklığı minimuma indirmek için çalışmalar yaparak yer seçimi problemi konusundan çalışmalarını başlatmıştır. Çalışma yapılan problem deponun kurulması için en uygun yer şartlarını sağlayabilen bölgeyi, işgücü kapasitesini, ulaşım olanaklarını kapsayarak en uygun görülen yerin seçilmesidir. Kapsanan noktalar göz önüne alınarak en uygun alternatif yerin seçilmesi sağlanmakta ve sonuç elde edilmektedir (Yapıcı ve diğ., 2020).

3.2. Dağıtım Ağı Optimizasyonunda Kullanılan Yöntemler

Kuruluş yeri seçim probleminde kesin matematiksel modeller, sezgisel yöntemler, ağırlık merkezi yöntemi, etken-puan yöntemi, çok ölçütlü karar verme yöntemleri gibi metotlar kullanılmaktadır. Yapılan Literatür araştırmalarında Karmaşık Tam Sayılı Programlama, Meta-Sezgisel Yaklaşımlar ve Çok Kriterli Karar Verme yöntemleri bu problem türünde oldukça sık kullanıldığı görülmüştür.

Kuruluş yeri seçimi problemi literatür taraması yapıldığında son yıllarda farklı yöntemlerin kullanıldığı görülmekte ve çok kriterli karar verme, Sezgisel yöntemler ve matematiksel programlama başlıca yöntemler olarak öne çıkmaktadır.

3.3. Dağıtım Ağı Optimizasyonu-Literatür Araştırması

İleri lojistik ve dağıtım ağı optimizasyonu üzerine yapılan literatür araştırmaları, son yıllarda hem yerli hem de yabancı kaynaklarda bu alanda çeşitli çalışmaların gerçekleştirildiğini ve farklı çözüm yöntemlerinin uygulandığını ortaya koymaktadır. Sezgisel yöntemlerle yapılan çalışmalara genel olarak bakıldığında, şu sonuçlar dikkat çekmektedir;

Kalfakakou ve arkadaşları (2003), eşzamanlı depolamada kısıtlamaları karşılayan en düşük depo sayısını belirlemek amacıyla bir sezgisel yöntem geliştirmiştir. Michel ve Van Hentenryck (2004), depo yeri problemlerinin çözümüne yönelik etkili bir tabu-arama algoritması sunmuştur. Askin ve ekibi (2014), genetik algoritmaları kullanarak depo yerleşimi, kapasite seviyeleri, dağıtım yolları ve stok miktarlarını optimize etmeye yönelik bir yöntem önermiştir. Yaobao ve ekibi (2013), otomobil yedek parça depolarında malların optimum tahsisini belirlemek için parçacık sürü optimizasyonu tekniğini kullanmıştır. Rath ve Gutjahr (2014), afet yardımı için üç hedefli depo yerleşimi ve

yönlendirme problemlerine yönelik bir sezgisel yaklaşım geliştirmiştir. Abo-Elnaga ve ekibi (2017), aktif setli güven bölgesi algoritmasıyla toplam dağıtım maliyetlerini minimize eden bir model tasarlamıştır (Sağanak, 2020).

Kronolojik sıraya göre yapılan Literatür araştırmasında ise çalışmalar kısaca aşağıdaki gibidir;

Ayöperken ve Ermiş (2011), “İnsansız Hava Araçları İçin Üs Konumlarının Kapsama Alanı Problemi Olarak Modellenmesi ve Eniyilenmesi” adlı çalışmalarında, insansız hava araçları (İHA) için en uygun üs konumlarını belirlemeyi bir Tesis Yeri Seçim Problemi olarak ele almıştır. Çalışmada, aday üs noktalarına maliyet, coğrafya, lojistik ve hava durumu gibi kısıtlar tanımlanmış ve problem, 0-1 Tamsayı Programlama Modeli ile GAMS programında çözülmüştür. Sonuç olarak, 29 senaryo için toplam 99 üs noktası belirlenmiş; 20 aday üs içerisinde tüm senaryolarda toplam 10 üs kullanılmış ve öncelik değerlerine göre en fazla hedefi kapsayacak şekilde İHA üs atamaları yapılmıştır.

Popović ve Brbaklić vd. (2017), belirli bir ağda kurulacak otomasyon cihazlarının optimal sayısını, türünü ve konumunu belirlemek için farklı cihaz türlerini (anahtarlar, FPI'ler vb.) aynı anda dikkate alan bir Karma Tamsayılı Doğrusal Programlama (MILP) tabanlı yaklaşım sunmuştur. Çalışmada, en etkili ağ otomasyon senaryosu, tüketicilerin ve üreticilerin kesinti maliyetleri (anlık, kısa ve uzun vadeli), yaygın olarak kullanılan ağ güvenilirliği endeksleri (SAIFI, SAIDI, MAIFI ve ASIDI), otomasyon cihazlarının maliyeti ve ekiplerin maliyetleri göz önünde bulundurularak belirlenmiştir. Önerilen yaklaşım, güvenilirliğin yalnızca güvenilirlik endeksleri veya kesinti maliyetleri ile ölçülmesi ya da her iki kriterin bir arada kullanılması durumunda en iyi otomasyon senaryosunun elde edilmesini sağlamıştır.

Tran, Nagy vd. (2018), alternatif bir akaryakıt istasyonu yerleşim problemini sezgisel bir algoritma ile ele almış ve gidiş-dönüş trafik hacmini maksimize etmeyi hedeflemiştir. Çalışma, alt problemleri çözerek en iyi istasyon konumlarını belirlemeye dayalı bir model sunmuştur. Aday istasyon kümesi, başlangıçta bir gevşeme modeliyle belirlenmiş ve daha sonra bazı istasyonların değiştirilmesiyle güncellenmiştir. Paralel hesaplama stratejisi, işlem süresini hızlandırmak için entegre edilmiştir. Deneysel sonuçlar, algoritmanın Genetik Algoritma ve Açgözlü Algoritmadan daha iyi performans sergilediğini ve

CPLEX çözücüyü kıyasla tüm optimal çözümleri daha kısa sürede elde ettiğini göstermiştir.

Brunaud ve Bassett vd. (2018), mevsimsel taleple uzun vadeli tahmini desteklemek için gerekli depoların sayısını, yerini ve kapasitesini belirlemek amacıyla bir Karma Tamsayılı Doğrusal Programlama modeli önermiştir. Model, ayrık nakliye maliyetleri, dinamik depo sözleşmeleri ve güvenlik stokunu içermektedir. Ayrık taşıma maliyetleri için alternatif formülasyonlar değerlendirilmiş ve tamsayı değişkenleriyle en verimli çözüm elde edilmiştir. Güvenlik stoku, parçalı doğrusal bir yöntemle hesaplanmış ve büyük ölçekli problemler için sıkılaştırma kısıtlamalarıyla çözüm süresi optimize edilmiştir. Model, 14 fabrika, 18 depo, 15 müşteri, 15 ürün, 36 zaman periyodu ve 14 mod içeren üç farklı vaka üzerinde test edilmiş ve başarılı sonuçlar elde edilmiştir.

Guo, Pan vd. (2018), belirsiz petrol kuyusu konumu altında petrol sahası lojistik depo yeri problemini incelemiştir. Monte Carlo simülasyonu, gelecekteki petrol kuyusu dağılımını modellemek için kullanılmıştır. Sürekli ve ayrık yerleşim modelleriyle altı uygun aday belirlenmiş, ardından Genetik Algoritma ve Diferansiyel Gelişim Algoritmaları ile optimal konum seçilmiştir. Çalışma, belirlenen konumun yıllık lojistik maliyetleri 55.000 Yuan azaltarak maliyet avantajı sağladığını göstermiştir.

Acar (2019), “Mühimmat Depo Yeri Seçimi ve Dağıtım Ağı Tasarımı Problemi” başlıklı yüksek lisans projesinde, mühimmat depolarının yer seçimi ve dağıtım ağı tasarımı problemini ele almıştır. Çalışmada, coğrafi olarak dağıtılmış askeri birliklere mühimmat dağıtımı için aday depo noktalarından optimum yerlerin seçimi ve depoların tür ile sayısının belirlenmesi hedeflenmiştir. Problem, mühimmat türlerinin depolardan birliklere taşınmasını da içeren bir maliyet minimizasyon modeliyle çözülmüştür. Model, GAMS programı kullanılarak çözülmüş ve 15 aday depo arasından 6 depo seçilerek tüm kısıtlar altında optimum sonuç elde edilmiştir.

Yuan, Zhang vd. (2019), Pekin'deki bir bisiklet paylaşım sisteminin optimal planlamasını, stratejik tasarım ve işletme kararlarını stokastik talep ve hizmet seviyesini dikkate alarak bütünlüklü bir yaklaşımla araştırmıştır. Çalışma, bisiklet istasyonlarının sayısı, konumu ve kapasitesini toplam filo boyutu, depo yeri, yeniden dengeleme ve bakım planlarıyla birleştirerek çözmeyi hedeflemiştir. Stokastik talep için senaryo tabanlı bir yaklaşım

uygulanmış ve Karmaşık Tamsayılı Doğrusal Programlama modeli ile gerçek planlama sonuçları karşılaştırılmıştır. Ayrıca modelin üç temel parametresi için kapsamlı duyarlılık analizleri yapılmıştır.

Wang vd. (2021), belirsizlik altında Acil Durum Depo Yeri ve Dağıtım Problemini çözmek için zaman maliyetine dayalı bir Karma Tamsayılı Programlama Modeli önermiştir. Modelde, zaman maliyeti, kaynak eksikliği cezası, alternatif kaynaklar, ulaşım araçları ve çoklu kaynak türleri değerlendirilmiştir. Parçacık Sürüsü Optimizasyonu (PSO) ve Değişken Komşuluk Araması (VNS), farklı ölçeklerdeki problemleri çözmek için kullanılmıştır. Ticari çözücü CPLEX ile yapılan karşılaştırmalarda, her iki algoritma da küçük ölçekli örneklerde aynı sonuçları verirken, büyük ölçekli örneklerde üstün performans göstermiştir.

4. YAPAY SİNİR AĞLARI

Gelişen teknolojiyle birlikte makine öğrenme yöntemleri, geleneksel tahmin yöntemlerine alternatif olarak daha yaygın bir şekilde kullanılmaya başlanmıştır. Bu yöntemlerden biri de insan beynindeki sinir hücrelerinden esinlenerek geliştirilen ve öğrenme yeteneğini modelleyen Yapay Sinir Ağları (YSA)'dır. Yapay sinir ağları, insan beyninin öğrenme yapısını modelleyen, yeni bilgileri türetebilen, keşfedebilen ve herhangi bir yardıma ihtiyaç duymadan öğrenme süreçlerini otomatikleştirebilen sistemler olarak tanımlanabilir [Elmas, 2003, Öztemel, 2003].

1943 yılında McCulloch ve Pitts tarafından geliştirilen ilk matematiksel model, insan beynindeki nöronların işleyişini temel almıştır (McCulloch ve Pitts, 1943). Bu modelin ardından, 1958'de Frank Rosenblatt tarafından geliştirilen Perceptron algoritması, YSA'nın sınıflandırma problemleri için kullanılabileceğini göstermiştir. Ancak, sınırlı bir öğrenme kapasitesine sahip olması nedeniyle YSA çalışmalarında bir süre duraklama yaşanmıştır (Rosenblatt, 1958).

1980'lerde "backpropagation" algoritmasının tanıtılmasıyla, YSA büyük bir ilerleme kaydetmiştir (Rumelhart ve diğ., 1986). Bu algoritma, çok katmanlı sinir ağlarının daha karmaşık problemlerde etkin bir şekilde kullanılmasını sağlamış ve YSA'nın uygulama alanlarını genişletmiştir.


2000'li yılların başından itibaren artan hesaplama gücü, büyük veri setlerinin erişilebilirliği ve optimizasyon algoritmalarındaki ilerlemeler, derin öğrenmenin önünü açmıştır. 2012 yılında Alex Krizhevsky ve ekibi tarafından ImageNet yarışmasında kullanılan derin konvolüsyonel sinir ağı (CNN), YSA'nın potansiyelini gözler önüne sermiş ve alanın yeniden popülerlik kazanmasını sağlamıştır (Krizhevsky ve diğ., 2012).

Günümüzde yapay sinir ağları, ileri beslemeli ve geri beslemeli modeller gibi farklı mimarilerle daha geniş bir problem yelpazesine uygulanmaktadır ((Çuhadar ve Kayacan, 2005), Öztemel, 2003). YSA'nın uygulama alanları; görüntü işleme, doğal dil işleme, biyoinformatik ve otonom sistemler gibi birçok disiplini kapsamaktadır. Bu evrim süreci, YSA'nın bilimsel ve endüstriyel uygulamalarda kritik bir rol oynamasına olanak tanımıştır.

Bir yapay sinir ağı modeli, giriş katmanı, çıkış katmanı ve bu iki katman arasında yer alan gizli katmanlardan oluşmaktadır. Giriş katmanı, modele veri sağlayan birimlerden oluşurken, gizli katmanlar verilerin işlenmesinden sorumludur. Her bir gizli katman, giriş verilerini ağırlık katsayıları ve eşik değerleri kullanarak işler ve çıktı katmanına iletir. Bu işlem, ağıın öğrenme süreci olan iterasyonlarla sürekli tekrarlanır [(Öztemel, 2003), Karahen, 2015)].

Yapay sinir ağlarının tasarımı, modelin yapılandırılması, uygun eğitim yönteminin seçilmesi ve performans değerlendirme aşamalarını kapsayan bir süreçtir. Eğitim sırasında, model veriler üzerinde hata analizleri yapılarak optimize edilir. Bu süreçte, performans değerlendirmesi için genellikle Hata Kareleri Ortalamasının Karekökü (Root Mean Squared Error - RMSE) ve Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error - MAPE) gibi metriklerden yararlanılmaktadır ([Elmas, 2003).

Yapay Sinir Ağları Katmanları Şekil 4.1’te belirtilmektedir.



Şekil 4.1 Yapay Sinir Ağ Katmanları

4.1. Yapay Sinir Ağlarının Özellikleri

Yapay Sinir Ağları (YSA), insan beyninin çalışma prensiplerinden esinlenerek geliştirilmiş hesaplama modelleridir. Bu ağlar, biyolojik sinir hücrelerinin işleyişini taklit ederek, öğrenme ve adaptasyon yetenekleri sayesinde karmaşık problemlerin çözümünde etkin bir şekilde kullanılmaktadır.

- **Adaptasyon Yeteneği:** YSA'lar, öğrenme süreçleri sayesinde farklı veri setlerine ve değişen koşullara uyum sağlayabilirler. Bu adaptasyon yeteneği, ağıın eğitim verileri üzerinden öğrenerek parametrelerini optimize etmesiyle mümkün olur. Özellikle

denetimli ve denetimsiz öğrenme yöntemleri kullanılarak, YSA'lar çeşitli uygulama alanlarında başarılı sonuçlar elde edebilirler (Mijwil, 2018).

- **Paralel İşlem Kapasitesi:** YSA'lar, insan beynindeki nöronların paralel işlem yapma yeteneğinden esinlenerek tasarlanmıştır. Bu sayede, büyük veri setleri ve karmaşık hesaplamalar paralel olarak işlenebilir, bu da işlem hızını ve verimliliği artırır. Özellikle grafik işlem birimlerinin (GPU) kullanımıyla, derin öğrenme modellerinin eğitimi hızlandırılmıştır (Shiruru ve Rajesh, 2017).
- **Genel İlişki Kurma:** YSA'lar, eğitim verileri arasındaki karmaşık ilişkileri öğrenerek, yeni ve görülmemiş veriler üzerinde genelleme yapabilirler. Bu özellik, modellerin farklı veri kümeleri üzerinde başarılı tahminler yapmasını sağlar. Örneğin, bir YSA modeli, daha önce karşılaşmadığı bir görüntüyü doğru bir şekilde sınıflandırabilir (Qamar 2023).
- **İnsan Beyninden Esinlenen Yapısal Özellikler:** YSA'lar, biyolojik sinir hücrelerinin işleyişini taklit eden yapay nöronlardan oluşur. Her bir yapay nöron, dendritler aracılığıyla aldığı girdileri işler, aksonlar aracılığıyla çıktılar üretir ve sinaps benzeri bağlantılarla diğer nöronlarla iletişim kurar. Bu biyomimetik yapı, YSA'ların öğrenme, hatırlama ve genelleme yapma yeteneklerini destekler (Akomolafe, 2016).

4.2. Yapay Sinir Ağları ve Öğrenme Teknikleri

Yapay Sinir Ağları (YSA), insan beyninin öğrenme mekanizmalarından esinlenerek geliştirilmiş ve farklı öğrenme teknikleriyle donatılmıştır. Bu teknikler, YSA'nın çeşitli veri türleri ve problem alanlarına uyum sağlamasına olanak tanır. Genel olarak üç ana başlık altında incelenir: denetimli öğrenme, denetimsiz öğrenme ve pekiştirmeli öğrenme.


- **Denetimli Öğrenme (Supervised Learning):** Bu yöntemde, model önceden etiketlenmiş veri setleri üzerinde eğitilir; yani her giriş verisine karşılık gelen doğru çıkış verisi mevcuttur. Model, giriş ve çıkışlar arasındaki ilişkiyi öğrenerek yeni, görülmemiş veriler için doğru tahminler yapmayı amaçlar. YSA'da sıkça kullanılan denetimli öğrenme algoritmalarından biri geri yayılım (backpropagation) algoritmasıdır. Bu algoritma, hatayı minimize etmek için ağırlıkların güncelleyerek öğrenmeyi sağlar. Ayrıca, Destek Vektör Makineleri (Support Vector

Machines - SVM) de sınıflandırma ve regresyon problemlerinde kullanılan etkili denetimli öğrenme yöntemlerindendir (Yılmaz, 2020).

- Denetimsiz Öğrenme (Unsupervised Learning): Denetimsiz öğrenmede, model etiketlenmemiş veri setleri üzerinde çalışır; yani sadece giriş verileri mevcuttur ve bunlar arasında anlamlı yapılar veya desenler keşfetmeye çalışır. Bu teknik, verilerin doğal gruplarını veya ilişkilerini belirlemek için kullanılır. Örneğin, K-means algoritması, verileri önceden belirlenmiş k sayıda kümeye ayırarak benzer özelliklere sahip veri noktalarını bir araya getirir. Temel Bileşen Analizi (Principal Component Analysis - PCA) ise, yüksek boyutlu verilerin boyutunu düşürerek verinin ana bileşenlerini ortaya çıkarır. Otoenkoderler (Autoencoders) ise, verinin sıkıştırılmış bir temsilini öğrenerek önemli özellikleri çıkarır ve gürültü azaltma gibi görevlerde kullanılır (URL-1, 2024).
- Pekiştirmeli Öğrenme (Reinforcement Learning): Pekiştirmeli öğrenme, bir ajanın bir ortam içerisinde deneyim kazanarak ve ödül-ceza mekanizmasıyla etkileşimde bulunarak optimal davranışlar geliştirmesini sağlayan bir makine öğrenmesi yöntemidir. Bu öğrenme tekniği, önceden etiketlenmiş veri setlerine ihtiyaç duymadan, çevreden alınan geri bildirimlerle çalışır. Ajan, yaptığı her eylem sonrasında bir ödül veya ceza alır ve bu geri bildirimlere dayanarak gelecekteki eylemlerini optimize eder. Ödül mekanizması, ajanın davranışlarını istenen hedefe yönlendirmede temel bir rol oynar. Örneğin, otonom araçların trafiği güvenli bir şekilde yönetmesi veya robotların belirli bir görevi yerine getirmesi için pekiştirmeli öğrenme algoritmaları başarıyla kullanılabilir. Pekiştirmeli öğrenmede sıkça kullanılan algoritmalar arasında Q-learning ve Politika Gradyanları (Policy Gradients) bulunmaktadır. Q-learning, ajanın her durum-eylem çiftine bir değer atayarak, ödülleri maksimize eden en iyi politikayı öğrenmesini sağlar. Politika Gradyanları ise karmaşık eylem alanlarında optimal politikayı doğrudan öğrenir. Bu yaklaşımlar, özellikle oyun teorisi, robotik ve otonom sistemler gibi karmaşık ortamlarda yüksek performans sunar. Pekiştirmeli öğrenme, uzun vadeli ödülleri dikkate alarak stratejik kararlar almayı desteklerken, etiketli veri gereksinimini ortadan kaldırarak geniş bir uygulama alanı sağlar (Gürsakal ve Aydın, 2023).

4.3. Yapay Sinir Ağı Türleri

Yapay sinir ağlarını yapılarına göre sınıflandırmak mümkündür. YSA'lar, ağ içindeki işaretlerin akış yönlerine göre ileri beslemeli ağlar (Feedforward Neural Networks - FNN) ve geri beslemeli ağlar (Recurrent Neural Networks - RNN) olarak ikiye ayrılmaktadır (Kasabov, 1996). İleri beslemeli ağlarda bilgi, girişten çıkışa doğru tek yönlü olarak iletilirken, geri beslemeli ağlar önceki çıktıları girişlere geri besleyerek ardışık veriler arasındaki bağımlılıkları modelleyebilir. Yapay Sinir Ağlarına ilişkin ağ modelleri Şekil 4.2'de gösterilmiştir.



Şekil 4.2. Sinir Ağları Türleri (Şenol, 2022)

4.3.1. İleri Beslemeli Ağlar

İleri beslemeli sinir ağları, yapay sinir ağlarının en basit şeklidir (Yaday ve diğ., 2015). Bu ağlarda bilgi, giriş katmanından başlayarak tek bir yönde, çıkış katmanına doğru akar. Ağ içindeki nöronlar katmanlara ayrılmıştır ve bir katmandaki hücrelerin çıktısı, bir sonraki katmandaki nöronlara ağırlıklar üzerinden giriş olarak iletilir (Çuhadar ve Kayacan, 2005).

Girdi katmanı, dış dünyadan aldığı bilgiyi doğrudan gizli katmana aktarır. Gizli katmanlar, bilgiyi işleyerek çıktı katmanına iletir ve böylece ağın çıktısı belirlenir. Gizli katmanlardaki nöron sayısı, problemin gerekliliklerine göre belirlenir. Ancak bu katmanların ve nöron sayısının optimal miktarını belirlemek için analitik bir yöntem

geliştirilmemiştir; bu nedenle genellikle deneme-yanılma yöntemiyle belirlenir (Efe ve Kaynak, 2006).

İleri beslemeli ağlarda sinyaller yalnızca girişten çıkışa doğru hareket eder ve bir katmandaki nöronlar aynı katmanda bulunan diğer nöronları etkilemez. Bu ağlar tamamen girdilere bağımlıdır ve dinamik özelliklere sahip değildir. Doğrusal ve doğrusal olmayan problemlerde uygulanabilen bu ağlar, sınıflandırma ve regresyon gibi temel görevlerde yaygın olarak kullanılmaktadır (Tolon ve Tosunoğlu, 2008).

4.3.2. Geri Beslemeli Ağlar

Geri beslemeli ağlar, çıktı düğümlerinden girdi düğümlerine geri dönen bağlantılara sahip olabilir ve bu sayede ağ içerisinde döngüler oluşturabilirler. Bu yapıları sayesinde, geri beslemeli ağlar bir tür belleğe sahiptir ve yalnızca mevcut girdilere değil, önceki tüm girdilere dayalı olarak çıktı üretebilirler (Yaday ve diğ., 2015). Bu özellik, zaman serisi analizi, dil modeli oluşturma ve konuşma tanıma gibi ardışık bağımlılıkların önemli olduğu uygulamalarda bu ağları etkili kılar.

Geri beslemeli ağların öğrenme sürecinde, girdiler ağdan geçirilir ve çıktılar bir döngü içerisinde tekrar giriş olarak beslenir. Ağın denge veya istikrar halinde olduğu söylenen durumda, çıktı değerleri değişmeden kalır. Dinamik bellek yapısı sayesinde, geri beslemeli ağlar belirli bir andaki çıktılarını hem önceki girdilere hem de mevcut girdiye dayanarak üretir.

Bu tür ağların örnekleri arasında Hopfield ağı (Hopfield, 1982), Elman ağı (Elman, 1990) ve Jordan ağı bulunmaktadır (Jordan, 1986). Elman ve Jordan ağları genellikle basit yapılarıyla öne çıkar ve temel dinamik bellek işlevlerini yerine getirir (Pham ve Karaboğa, 2000)

4.4. Yapay Sinir Ağı Tasarım Mimarisi

Bir yapay sinir ağı oluşturulduktan sonra, ağın belirli bir probleme uygun şekilde yapılandırılması ve eğitilmesi gerekmektedir. Yapılandırma, örnek verilerin çözülmek istenen probleme göre düzenlenmesini ifade ederken, eğitim süreci, ağın içindeki ağırlık ve bias değerlerinin ayarlanarak öğrenmenin sağlanmasıdır. Bu süreçte karşılaşılan en

temel soru, ağın hangi algoritma ile eğitileceğidir. Ancak, veri setinin yapısı, ağıdaki ağırlıklar, nöron sayıları ve ağın kullanım amacı gibi pek çok faktör bu seçimi etkilediğinden, en iyi eğitim algoritmasını belirlemek oldukça zordur (Beale ve diğ., 2018).

Yapay sinir ağı tasarımında bir diğer önemli soru, gizli katman ve nöron sayısının nasıl belirleneceğidir. İleri beslemeli yapay sinir ağlarında (Feedforward Neural Networks - FNN) teoride tek gizli katmanın yeterli olduğu kanıtlanmış olsa da, pratikte bu sorunlar genellikle birden fazla katmanda çözülebilmektedir (Bebis ve diğ., 1994). Gizli katmanlardaki nöron sayısını belirlemek için literatürde farklı yaklaşımlar bulunmaktadır. Ancak, bu sayıyı optimize etmek için örnek veri yapısı, girdi ve çıktı sayısı, eğitim algoritması ve aktivasyon fonksiyonu gibi birçok faktörün bir arada değerlendirilmesi gerekmektedir [(Xu ve Chen, 2008), (ISarle, 2002)].

Gizli Nöron Sayısını Belirlemek için Genel Yaklaşımlar:

- Gizli nöron sayısı, girdi katmanı ve çıktı katmanı arasındaki bir değer olmalıdır.
- Gizli nöron sayısı, girdi katmanının $2/3$ 'ü kadar olmalıdır.
- Gizli nöron sayısı, girdi katmanının 2 katından az olmalıdır (Panchal ve diğ., 2011).

Bu yaklaşımlar, ağın performansını optimize etmek için bir rehber niteliğinde olsa da, en uygun yapılandırmayı belirlemek deneme-yanılma yöntemi ve çeşitli optimizasyon teknikleri gerektirebilir.

4.5. YSA Uygulama Alanları

Yapay sinir ağları, doğrusal olmayan, çok boyutlu, gürültülü ve eksik verilere dayanan karmaşık problemlerin çözümünde etkili bir yöntem olarak öne çıkmaktadır. Ayrıca, matematiksel modelin mevcut olmadığı durumlarda da yaygın bir şekilde tercih edilmektedir. Bu ağlar, aşağıdaki işlevleri yerine getirme kapasitesine sahiptir (Öztemel, 2012):

- Sınıflandırma: Verilerin kategorilere ayrılması.
- İlişkilendirme: Veri grupları arasında bağlantı kurulması.

- Zaman Serisi Analizi: Geçmiş verilerden yararlanarak gelecekteki eğilimlerin tahmini.
- Sinyal Filtreleme: Verilerden istenmeyen gürültülerin ayıklanması.
- Veri Sıkıştırma: Bilgilerin daha az yer kaplayacak şekilde yeniden düzenlenmesi.
- Örüntü Tanıma: Verilerdeki belirli desenlerin algılanması.
- Doğrusal Olmayan Sinyal İşleme: Karmaşık sinyal yapılarına müdahale edilmesi.
- Doğrusal Olmayan Sistem Modelleme: Karmaşık sistemlerin davranışlarının simüle edilmesi.
- Optimizasyon: Belirli bir hedef doğrultusunda en iyi çözümlerin bulunması.

Bu özellikleri, yapay sinir ağlarını geniş bir uygulama yelpazesinde etkili bir çözüm aracı haline getirmektedir.

Yapay sinir ağları (YSA), farklı sektörlerde çeşitli problemleri çözmek için etkili bir araç olarak kullanılmaktadır. Öne çıkan uygulama alanları şunlardır:

- Arıza Analizi ve Tespiti: Sistemlerin düzenli çalışma koşullarını öğrenerek arızaların tahmin edilmesini sağlar. Elektrikli makineler, uçaklar ve devrelerin hata analizi için kullanılmaktadır.
- Tıp: Yapay sinir ağları, tıbbi sinyallerin analizinde, kanser hücrelerinin tespitinde ve hastane giderlerinin optimize edilmesinde önemli bir etkiye sahiptir.
- Savunma Sanayi: Silah sistemlerinin otomasyonu, hedeflerin izlenmesi ve nesne/görüntü tanıma gibi uygulamalarda etkin bir şekilde kullanılmaktadır.
- Haberleşme: Veri ve görüntü sıkıştırma işlemlerinin yanı sıra otomatik bilgi sunma sistemlerinde yapay sinir ağları tercih edilmektedir.
- Üretim: YSA, üretim süreçlerinin optimizasyonu, ürün analizi ve tasarımı, kalite kontrol ve yönetim gibi alanlarda yaygın bir şekilde uygulanmaktadır.
- Otomasyon ve Kontrol: Otomatik pilot sistemleri, yol planlama ve elektrikli sürücü sistemlerinin kontrolünde yapay sinir ağları etkili çözümler sunmaktadır.
- İstatistik: Regresyon ve kümeleme analizleri gibi klasik istatistik yöntemlerine alternatif olarak yaygın bir şekilde kullanılmaktadır.

- Finans: Borsa endeksi, enflasyon tahmini, kredi değerlendirme, döviz kuru tahmini ve kredi kartı hilelerinin tespiti gibi finansal uygulamalarda etkin bir şekilde kullanılmaktadır (Kuru, 2017).

Yapay sinir ağları (YSA), teknolojinin hızla gelişmesiyle birlikte çok çeşitli alanlarda yenilikçi çözümler sunmaktadır. Güncel ve trend uygulama alanları arasında özellikle doğal dil işleme (NLP) öne çıkmaktadır; metin analizi, dil çevirisi ve sohbet botları gibi alanlarda YSA, güçlü bir araç olarak kullanılmaktadır. Otonom araçlar, çevre algılama, yol planlama ve karar verme süreçlerinde YSA'nın önemli bir rol oynadığı bir diğer popüler uygulama alanıdır. Siber güvenlik ise, anomali tespiti, saldırıların önlenmesi ve güvenlik tehditlerinin algılanmasında YSA'nın etkili bir şekilde kullanıldığı bir başka kritik alandır.

Bunun yanı sıra, görsel sanatlar ve yaratıcı uygulamalarda yapay sinir ağları, sanat eserleri üretme, müzik besteleme ve içerik oluşturma süreçlerinde devrim yaratmaktadır. Tarım teknolojileri de YSA'nın etkin olduğu bir diğer alan olup, ürün verimliliği, hastalık tespiti ve otomasyon gibi süreçlerde kullanılmaktadır. Ayrıca, eğitim teknolojileri alanında, öğrenci performansını izleme, kişiselleştirilmiş öğrenme deneyimleri sağlama ve eğitim materyallerinin geliştirilmesi için YSA'dan yararlanılmaktadır. Bu uygulamalar, YSA'nın esnek yapısının ve öğrenme kabiliyetinin farklı sektörlerde değerli çözümler sunmasını sağlamaktadır.

Bu trendler, YSA'nın yalnızca mevcut kullanım alanlarını geliştirmekle kalmayıp, aynı zamanda yeni teknolojik inovasyonlar için de geniş bir potansiyel taşıdığını göstermektedir.

4.6. YSA Avantajları ve Dezavantajları

Yapay sinir ağları bilgiyi, klasik programlama algoritmalarının aksine, tüm ağda yayılmış bir şekilde saklar. Bu özellik, bilginin bir kısmı kaybolduğunda dahi ağın genel performansını etkilemez ve hata toleransının yüksek olmasını sağlar. Ağdaki bir veya birden fazla hücre işlevini yitirse bile ağ, çıktı üretmeye devam edebilir.

Yapay sinir ağları, yayılmış bir hafızaya sahip olup, eğitim sırasında beklenen çıktılara ulaşabilmesi için örneklerle eğitilmelidir. Öğrenme tamamlandıktan sonra ağ, daha önce

karşılaşmadığı durumlar için bile tahmin yapabilir. Ancak ağ mimarisinin en iyi şekilde oluşturulması için kesin kurallar bulunmamakta ve süreç büyük ölçüde deneme-yanılma yöntemine dayanmaktadır. Bu durum, ağların "kara kutu" olarak anılmasına yol açsa da yapay sinir ağlarının yaygın kullanımını engellememektedir.

Donanımsal gereksinimlerin fazla olması bir dezavantaj olarak görülse de gelişen paralel işlemci teknolojileri, büyük veri içeren yapay sinir ağlarının yüksek performansta çalışmasını mümkün kılmaktadır. Tekil ya da birleştirilmiş yapay sinir ağları, aynı anda birden fazla görevi yerine getirebilir. Öğrenme yeteneği sayesinde, yapay sinir ağları modern teknolojinin temel taşlarından biri olarak kabul edilmektedir (Adıgüzel, 2022).

4.6.1. Yapay Sinir Ağlarının Avantajları

Yapay sinir ağları, klasik programlama yöntemlerine kıyasla çeşitli avantajlara sahiptir. Bu avantajlar, YSA'nın esnekliğini ve geniş uygulama alanlarını destekleyen temel özelliklerini oluşturmaktadır:

- Bilginin Ağ Genelinde Saklanması: Veri kaybı durumunda bile ağ çalışmaya devam eder.
- Eksik Veri ile Çalışabilme: Eğitildikten sonra eksik bilgilere rağmen çıktı üretebilir.
- Hata Toleransı: Birden fazla hücrenin bozulmasına rağmen çalışabilir.
- Dağıtık Hafıza: Örnek verilerle eğitilen ağ, öğrendiklerini hafızasında tutar.
- Dereceli Bozulma: Ağ, zamanla yavaş bir şekilde bozulur.
- Makine Öğrenimi Yeteneği: Olayları öğrenip benzer durumlarda karar verebilir.
- Paralel İşlem Yeteneği: Aynı anda birden fazla işlem gerçekleştirebilir.

4.6.2. Yapay Sinir Ağlarının Dezavantajları

Yapay sinir ağlarının avantajlarına rağmen, bazı sınırlamaları ve dezavantajları da bulunmaktadır. Bu dezavantajlar, YSA kullanımında dikkat edilmesi gereken noktaları oluşturur:

- Donanım Bağımlılığı: Paralel işlemciler gerektirir.
- Davranışların Açıklanamaması: Ağın nasıl bir çözüm ürettiği net değildir, bu güven sorununa yol açabilir.

- Uygun Ağ Yapısını Belirleme Zorluğu: Yapı deneme-yanılma yöntemiyle bulunur.
- Problem Gösterim Zorluğu: Veriler numerik değerlere dönüştürülmelidir.
- Eğitim Süresinin Belirsizliği: Hata oranının belirli bir seviyeye inmesi yeterli olmayabilir (Şenol, 2022).


4.7. Yapay Sinir Ağları Algoritma Akışı

Bir yapay sinir ağının eğitimi, eğitim setindeki veriler kullanılarak ağırlıkların güncellenmesiyle gerçekleştirilir. Eğitim, tüm eğitim çiftleri işlenip toplam hata istenilen seviyenin altına inene kadar devam eder. Eğer toplam hata belirlenen seviyenin üstünde kalırsa, tüm veri seti algoritmaya tekrar sunulur ve süreç yeniden başlatılır. Bu döngünün amacı, ağın girişlere karşılık gelen doğru çıktıları öğrenmesini ve hatayı minimum seviyeye indirmesini sağlamaktır. Ancak, hata değeri azalmayıp artmaya başlarsa, bu durum ağın genelleme yeteneğini kaybettiğini gösterir ve eğitim süreci durdurulur (Uçarsu, 2022).

- Sigmoid Fonksiyon Kullanılarak Eğitim Algoritması:
 - Başlangıç Ağırlıklarının Atanması: Ağırlık değerleri başlangıçta rastgele atanır.
 - Durma Kriteri Kontrolü: Eğer durma kriteri sağlanmamışsa, adımlar tekrar edilir.
 - Eğitim Çiftlerinin İşlenmesi: Eğitim setindeki her çift için aşağıdaki adımlar gerçekleştirilir:
 - Giriş Katmanı İşlemi: Giriş verisi, giriş katmanında alınır ve gizli katmana iletilir.
 - Gizli Katman İşlemi: Gizli katman, giriş verilerini ve bias değerlerini ağırlıklandırarak toplar.
 - Transfer Fonksiyonu Uygulaması: Toplanan veriler, transfer fonksiyonundan (örneğin, sigmoid fonksiyonu) geçirilerek çıktı katmanına gönderilir.

Bu süreç, yapay sinir ağının öğrenmesini ve hata değerini optimize etmesini sağlar.

5. HİBRİT MODEL KURGUSU



Şekil 5.1. Araştırma Yapılan Model Akışı

Şekil 5.1’de sunulan Araştırma Modeli Akışı, çalışmada izlenen metodolojik yaklaşımı özetlemektedir. Bu tez çalışmasında, sektörde uzun yıllardır lider konumda bulunan bir şirketin geçmiş satış verileri kullanılarak, Makine Öğrenmesi teknikleriyle geleceğe yönelik talep tahminlemesi gerçekleştirilecektir.


Tahminleme sonuçları, değişken talep yapısını göz önünde bulundurarak lojistik depolarının optimum konumlandırılması ve dağıtım ağının etkin şekilde yapılandırılması için temel girdi olarak kullanılacaktır. Dağıtım Ağı Optimizasyonu, doğrusal programlama ve karışık tam sayılı programlama yaklaşımları ile ele alınarak, maliyetlerin minimize edilmesi ve servis seviyelerinin artırılması hedeflenmektedir.

Bu hibrit modelde, mevsimsel etkiler, enflasyon, döviz kuru ve sektörel indeksler gibi dışsal değişkenler, tahminleme sürecinde dikkate alınarak modelin doğruluğu artırılabilecektir. Yapay Zeka destekli talep tahminleme aşaması, optimizasyon sürecine doğrudan veri sağlayarak daha dinamik ve gerçekçi bir dağıtım stratejisi geliştirilmesine olanak tanıyacaktır. Sonuç olarak, tahmin doğruluğunu maksimize eden ve operasyonel verimliliği artıran bütünlük bir lojistik yönetim modeli oluşturulacaktır.

6. UYGULAMA

6.1. Mevcut Durum Değerlendirmesi

Firmanın Türkiye çapındaki tüm illerde yaptığı satışlar incelendiğinde 2016 yılında 153 bin ton ürün sattığı, 2021 yılında satışların tavan yaptığı 2023 yılında ise 173 bin tona düştüğü görülmektedir.



Şekil 6.1. Yıllara Göre Satış Toplamları

Gerçekleşen satış rakamları İl bazında ve aylık bazda olacak şekilde de elleçlenmiş olup yıl bazında toplam olarak Şekil 6.1’de gösterilmiştir.

İL	PLAKA	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18
ADANA	1	135.538	288.011	380.606	403.774	399.799	894.357	508.801	175.366	550.342	268.782	664.332	601.074	303.070	465.036	442.243	652.950	430.300	619.865
ADYAMAN	2	4.756	231	13.473	10.779	14.920	11.037	13.089	23.525	3.765	32.245	14.620	18.910	0	462	0	29.966	50.097	750
AFYONKARAHİSAR	3	3.554	41.115	108.538	117.234	53.722	131.263	123.365	100.054	41.962	91.623	65.647	59.406	579	37.667	143.557	169.802	102.916	150.646
AGRI	4	0	659	24.985	62.313	55.194	29.241	16.291	16.973	24.957	5.299	32.015	225	737	737	21.644	68.635	23.945	16.809
AMASYA	5	4.565	11.062	7.706	18.646	7.930	24.435	6.950	9.024	5.818	14.785	16.314	7.959	0	368	4.712	13.704	7.702	6.667
ANKARA	6	96.070	464.104	1.153.181	1.292.701	705.202	1.174.293	606.741	643.445	538.006	850.946	496.329	1.285.679	163.699	876.443	539.526	809.541	745.475	510.729
ANTALYA	7	375.883	372.733	705.490	534.113	320.242	497.166	161.391	267.282	267.320	506.405	279.964	125.796	267.374	318.540	574.462	580.520	191.128	165.969
ARTVIN	8	9.272	2.373	29.984	23.062	7.450	8.830	3.745	15.483	8.929	10.034	6.685	485	0	13.339	2.731	2.205	8.703	6.901
AYDIN	9	22.103	18.188	31.863	55.531	28.311	30.132	15.783	18.341	6.725	15.021	21.807	32.429	22.147	37.667	54.715	29.890	14.004	14.854
BALIKESİR	10	90.756	222.753	598.870	638.654	578.568	230.928	147.995	146.541	283.039	307.128	241.533	278.744	156.101	324.054	343.777	412.309	237.280	461.759
BİLECEK	11	0	5.804	677	1.977	1.207	5.833	3.553	1.957	4.629	4.299	985	6.299	0	0	358	165	3.381	0
BİNGÖL	12	0	0	111.127	90.907	73.881	53.948	37.474	42.284	67.434	47.930	7.043	116	0	0	29.822	30.190	28.781	9.489
BITLİS	13	0	0	4.013	11.959	28.357	17.883	12.560	16.521	13.461	5.757	5.977	0	0	0	732	2.472	11.559	4.000
BOLU	14	0	275	8.813	8.995	14.954	18.578	5.465	10.282	8.598	2.226	2.981	775	0	12.497	17.752	17.506	5.069	21.566
BURDUR	15	0	8.515	7.645	6.496	6.625	3.232	2.050	2.395	1.808	162	624	0	606	0	27.448	3.440	4.284	413
BURSA	16	365.383	434.156	722.918	933.696	654.871	498.027	305.656	512.845	488.338	759.177	505.153	599.114	222.258	688.358	520.913	820.932	714.330	1.024.505
ÇANAKKALE	17	537	8.918	14.343	8.724	1.752	1.963	9.433	1.819	2.140	3.490	1.264	826	242	2.635	8.002	20.989	15.522	6.581

Şekil 6.2. İllere ve Aylara Göre Satış Rakamları

Gerçekleşen satış rakamları İl-Plaka ve ay bazında tahminleme modeline uygun olarak Şekil 6.2’de de gösterildiği üzere uygun formata getirilmiştir. Bu tablo daha sonra Matlab’te oluşturulacak algoritmaya girdi olarak sağlanacaktır.

6.2. Matlab Üzerinde YSA İle Talep Tahminleme


Satış verileri 2016-2023 yılları arasında aylık bazda olacak şekilde düzenlenmiştir. 81 ilin 12 yıllık satış verisi aylık bazda toplamda 96 x 81 olarak Şekilde 6.3'te gösterilen Excel'de Matris haline getirilmiştir.

A1	ESTABULU																										
	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	AA	AB
ESTABULU	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
YAMMAM	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
GAZIANTEP	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ANTALYA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ANKARA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ISPARTA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ADANA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
SAMSON	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ERZURUM	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ERZIN	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
KONYA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
KOHA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
DEMLI	1.57841	1.62219	2.2926	2.4068	7.726	28.801	4.0016	4.61	61.273	11.018	0.0185	1.00119	1.00185	1.14721	1.15839	0.1532	0.171	1.00178	0.0178	0.0178	0.0178	0.0178	0.0178	0.0178	0.0178	0.0178	0.0178
YAMMAM	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ERZURUM	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ERZIN	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ISPARTA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ADANA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
BALIKESIR	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ERZURUM	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ERZIN	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ISPARTA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ADANA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
YAMMAM	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
KONYA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
SAMSON	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
GAZIANTEP	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
YAMMAM	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ERZURUM	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ERZIN	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ISPARTA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ADANA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
SAMSON	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ERZURUM	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ERZIN	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
KONYA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
KOHA	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
DEMLI	1.57841	1.62219	2.2926	2.4068	7.726	28.801	4.0016	4.61	61.273	11.018	0.0185	1.00119	1.00185	1.14721	1.15839	0.1532	0.171	1.00178	0.0178	0.0178	0.0178	0.0178	0.0178	0.0178	0.0178	0.0178	0.0178
YAMMAM	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.4872	1.2015	0.1515	1.0586	1.5067	1.8672	1.08832	1.3101	1.7864	1.67883	1.711	1.9801	1.51052	1.8148	1.4847	1.4847	1.4847	1.4847
ERZURUM	1.0447	0.9871	1.8411	2.0102	2.7978	7.744	1.6088	2.1434	3.0843	1.																	

Şekil 6.3. 81 İlişin 12 Yıllık Satış Verisi

MATLAB ortamında gerçekleştirilen çalışmada, satış verileri Excel dosyasından xlsread fonksiyonu ile aktarılmış ve 81 şehir için 24 aylık tahmin yapılması hedeflenmiştir. Öncelikle, her şehir için satış verileri minimum ve maksimum değerler kullanılarak normalize edilmiş ve yapay sinir ağı (YSA) modeline uygun hale getirilmiştir. Gizli katmanında 10 nöron bulunan ve Levenberg-Marquardt algoritması ile eğitilen bir YSA modeli oluşturulmuştur. Model, geçmiş satış verileri ile eğitildikten sonra, her şehir için gelecekteki 24 aylık satış tahminleri gerçekleştirilmiş ve sonuçlar bir matris içerisinde saklanmıştır. Bu süreç, tahminlerin doğruluğunu artırmak için sistematik bir veri işleme ve modelleme yaklaşımı sunmaktadır. Şekilde 6.3.'te olduğu gibi Matlab'te yapılan kodlamada Excel Satış Datası çekilir (81 x 96).

Satış Verisi daha sonra Matlab'te Fitnet Algoritması üzerinden oluşturulan tahminleme modeline Şekil 6.4'te de görüldüğü üzere girdi değişkeni olarak sağlanır.



Şekil 6.4. Matlab Kodlama Ekranı


Şekil 6.5'te görüldüğü gibi satış verisi alındığı format ile algoritmada kullanılır.

	1	2	3	4	5	6	7	8	9	10	11	12
1	1.0430e...	1.6418e...	2.3316e...	2.7307e...	1.6083e...	2.1433e...	1.5888e...	1.4871e...	1.2020e...	2.0937e...	1.5568e...	1.5672e...
2	6.3737e...	1.2934e...	1.7744e...	1.7251e...	1.1375e...	1.3427e...	6.1699e...	7.6849e...	1.8883e...	6.4898e...	1.3103e...	9.7173e...
3	2.7848e...	5.1532e...	6.7634e...	8.0800e...	7.9851e...	5.4071e...	3.5488e...	4.5273e...	4.8021e...	5.7239e...	4.4886e...	4.8338e...
4	3.6538e...	4.3416e...	7.2282e...	9.3389e...	6.5487e...	4.9603e...	3.0566e...	5.1284e...	4.8834e...	7.5918e...	5.0515e...	5.9911e...
5	9.6070e...	4.6410e...	1.1532e...	1.2927e...	7.0520e...	1.1743e...	6.0674e...	6.4345e...	5.3801e...	8.5095e...	4.9633e...	1.2857e...
6	3.2566e...	5.9907e...	9.0199e...	8.9291e...	7.8130e...	1.0780e...	2.8766e...	5.3889e...	7.0672e...	5.7567e...	4.3835e...	3.8691e...
7	1.3554e...	2.8801e...	3.8061e...	4.0377e...	3.9980e...	8.9436e...	5.0880e...	1.7537e...	5.5034e...	2.6878e...	6.6433e...	6.0107e...
8	1.2618e...	3.4841e...	6.0904e...	6.6962e...	3.2520e...	7.5176e...	4.7840e...	2.5963e...	3.5825e...	4.9343e...	5.5477e...	5.4793e...
9	8.9041e...	2.5694e...	5.0848e...	6.1518e...	3.1396e...	4.6394e...	4.7338e...	5.3853e...	2.3850e...	5.4547e...	2.4466e...	3.3763e...
10	1.0628e...	2.1435e...	4.9139e...	5.2323e...	4.9042e...	6.1257e...	1.7041e...	4.7320e...	3.6859e...	7.6717e...	2.5629e...	5.2783e...
11	3.7588e...	3.7273e...	7.0549e...	5.3411e...	3.2024e...	4.9717e...	1.6139e...	2.6728e...	2.6732e...	5.0640e...	2.7996e...	1.2580e...
12	1.1678e...	4.1008e...	1.1734e...	5.8830e...	3.7710e...	3.9595e...	5.0426e...	6.2339e...	3.3708e...	4.2349e...	2.4634e...	1.3583e...
13	8.0048e...	3.6107e...	2.6429e...	6.8145e...	3.6451e...	5.1181e...	1.7876e...	2.6838e...	3.1647e...	4.5511e...	2.8244e...	3.8509e...
14	1.1796e...	9.5221e...	8.2927e...	7.7028e...	4.6092e...	4.6040e...	6.1727e...	5.1800e...	6.0952e...	1.0081e...	5.0855e...	4.1742e...
15	1.5752e...	1.7635e...	2.3479e...	2.3241e...	8.5975e...	1.2279e...	6.0018e...	8.3192e...	1.0938e...	1.0133e...	4.3868e...	8.3844e...
16	875	3.0206e...	4.6058e...	6.8095e...	4.2254e...	3.8754e...	2.8823e...	2.1797e...	4.3747e...	3.0721e...	1.9054e...	3.4207e...
17	1.3600e...	4.1285e...	7.9519e...	5.6818e...	3.5831e...	5.3225e...	3.2654e...	3.8488e...	3.4068e...	5.5451e...	1.9326e...	4.2454e...
18	9.0756e...	2.2275e...	5.9887e...	6.3865e...	5.7857e...	2.3093e...	1.4800e...	1.4654e...	2.8304e...	3.0713e...	2.4153e...	2.2784e...
19	6.2947e...	7.6632e...	1.5264e...	5.6774e...	2.0002e...	1.3933e...	2.8747e...	2.3419e...	2.2429e...	1.9789e...	2.2528e...	2.7800e...
20	3.2380e...	3.0561e...	6.1818e...	5.7759e...	4.3885e...	6.7637e...	1.5847e...	2.6908e...	2.9432e...	2.2516e...	2.9364e...	7.0168e...
21	1.1475e...	1.5949e...	8.3552e...	1.0914e...	5.8086e...	5.9800e...	5.9375e...	1.1682e...	4.8474e...	1.7082e...	1.1622e...	3.4873e...
22	0	9.1209e...	9.3158e...	3.5192e...	2.7566e...	2.0814e...	9.5343e...	9.1305e...	9.4688e...	2.1777e...	8.3964e...	3.3975e...
23	2.2103e...	1.8188e...	3.1863e...	5.5531e...	2.8311e...	3.0132e...	1.5783e...	1.8341e...	6.7247e...	1.5021e...	2.1807e...	3.2429e...
24	2.3448e...	1.2194e...	8.2765e...	1.7057e...	2.1591e...	1.9253e...	8.9845e...	1.1255e...	1.3147e...	2.1765e...	3.6742e...	9.8414e...

Şekil 6.5. Satış Verisinin Matlab'e Aktarılması


Şekilde 6.6.'da görüldüğü üzere iterasyonların sonuçlanması ile birlikte algoritma tamamlanır.

MATLAB ortamında geliştirilen yapay sinir ağı (YSA) modelinin eğitimi, Levenberg-Marquardt algoritması kullanılarak gerçekleştirilmiş ve modelin performansı doğrulama veri kümesi ile değerlendirilmiştir.



Şekil 6.6. Matlab Algoritma Sonucu


Eğitim süreci boyunca hata metriği olarak ortalama kare hatası (MSE) kullanılmış ve model, belirlenen doğrulama kriterine ulaşıldığında eğitim durdurulmuştur. Eğitim sırasında 9 epoch tamamlanmış ve modelin performansı başarıyla optimize edilmiştir. Eğitim sonuçları, gelecekteki 24 aylık tahminlerin yapılabilmesi için modelin hazır olduğunu göstermektedir. Bu süreçte, verilerin etkili şekilde işlenmesi ve doğrulama adımları, tahminlerin güvenilirliğini artırmıştır.



Şekil 6.7. Mean Squared Error Çıktısı


Şekilde 6.7'de eğitim, doğrulama ve test veri setleri için hata oranları (Mean Squared Error, MSE) gösterilmektedir. Doğrulama performansı en iyi sonucu 3. epoch'ta

(0.14735) vermiştir. Bu noktadan sonra doğrulama hatası artış eğilimindedir, bu da modelin aşırı öğrenme (overfitting) riskine işaret eder. Eğitim hatası sürekli azalırken, test ve doğrulama hatalarının seyri, modelin genelleme kabiliyetini değerlendirmek için kritiktir.



Şekil 6.8. Hata Histogramı


Şekilde 6.8’de gösterilen hata histogramında, modelin tahminleri ile gerçek hedefler arasındaki farkların dağılımı gösterilmektedir. Histogram, hataların büyük bir kısmının sıfıra yakın olduğunu, dolayısıyla modelin tahminlerinin genelde doğru olduğunu göstermektedir. Ancak, birkaç uç değer (outlier) modelin bazı durumlarda daha yüksek hata yaptığını göstermektedir.



Şekil 6.9. Hedef ve Tahmin Uyumu

Şekilde 6.9’da bulunan grafik modelin hedef değerlerle uyumu gösterilmektedir. Üstte modelin tahmin çıktıları ve hedefler arasındaki farklar, altta ise tahmin hataları verilmiştir. Model genel olarak hedeflere yakın tahminler yapmıştır, ancak bazı

bölgelerde yüksek sapmalar görülmektedir. Grafikteki hataların küçük ve dengeli olması, modelin iyi bir tahmin performansı sergilediğini destekler.




Şekil 6.10 İl ve Ay Bazlı İlk Tahmin Verileri

Şekil 6.10’da görüldüğü üzere İl ve Ay Bazlı Tahmin sonuçlarının ilk çıktısı alınmıştır.


Min-Max normalizasyon yöntemi uygulanarak ve olası negatif değerler sıfıra ayarlanarak yapılan tahmin sonuçlarında, 81 şehir için 24 aylık satış tahminleri tablo halinde düzenlenmiştir. Tahminler, modelin geçmiş verilere dayalı olarak gelecekteki aylık satış miktarlarını yüksek doğrulukla öngörebildiğini göstermektedir. Her şehir için yapılan tahminler, boyut ve zaman bazında farklılık göstermekte olup, modelin genelleme kabiliyetinin farklı veri setlerinde başarılı olduğunu işaret etmektedir. Tahmin sonuçları, gelecekteki stratejik planlama ve satış tahmini kararlarında kullanılabilecek güvenilir bir referans oluşturmaktadır.

Şekil 6.11’de görüldüğü üzere 81 ilin 24 aylık tahmini verileri 81x24’lük matris halinde Matlab Workspace kısmından değişkenler alınır.




Şekil 6.11. Matlab Kodlama Görüntüsü

81 ilin 2024-2025 tahmini verilerinin grafiksel kontrolü için en büyük 3 ilin trendi üzerinden rassal kontrol sağlanır. Şekilde 6.12’de Ankara ili, Şekil 6.13’te İstanbul ili ve Şekil 6.14’te İzmir illerinin gerçekleşen ve tahmini satışları trend halinde gözlemlenir. Normalizasyon sonrası grafiklerde sıfır değer veya negatif satış olup olmadığı kontrol edilir. Uç değerlerde seyreden tahminlerin olup olmadığı kontrol edilir.



Şekil 6.12. Ankara İli Gerçekleşen ve Tahmini Satışlar



Şekil 6.13. İstanbul İli Gerçekleşen ve Tahmini Satışlar



Şekil 6.14. İzmir İli Gerçekleşen ve Tahmini Satışlar

Matlab'te Yapay Sinir Ağları Algoritması ile yapılan tahminleme sonuçları Mevcut Talep Excel'inde Şekil 6.15'te de görüldüğü üzere 97-120. Aylar arasına yapıştırılır.

Şekil 6.15. Tahmini Satışların Excel Görüntüsü

Satış verileri plakaya göre sıralaması yapılır. Yıllık bazda ve tahminlemesi yapılan 2024-2025 yılları içinde toplamalar alınır.

Şekilde 6.16'da gösterildiği üzere 81 ilin mevcut satışlarına ek olarak tahmini satışlar aylık ve yıllık toplam olarak Excel'de elleçlenir ve analize uygun hale getirilir.

6.3.1. Optimizasyon Parametreleri;

6.3.1.1. Amaç Fonksiyonu ve Tanımları

Amaç fonksiyonu, toplam operasyon maliyetini minimize ederek, dağıtım ağı içinde daha verimli ve sürdürülebilir bir yapı oluşturmayı hedeflemektedir. Bu optimizasyon süreci, maliyetlerin ayrıntılı bir şekilde modellenmesini ve her bileşenin lojistik süreçlerdeki etkisinin dikkate alınmasını gerektirir. Operasyon maliyeti, aşağıdaki ana bileşenlerden oluşmaktadır:

- **Besleme Maliyeti:** Fabrikadan, depo açılacak ile yapılan TIR bazlı ürün sevkiyatının maliyetini ifade eder. Bu maliyet, yıllık taşınan ürün miktarına (örneğin, 100 TIR) ve her sefer için belirlenen maliyete göre hesaplanmaktadır. Bu bileşen, ana depo konumunun fabrikaya olan mesafesinden doğrudan etkilenmektedir ve taşımacılık maliyetlerini optimize etmek için kritik öneme sahiptir.
- **Toplam Dağıtım Maliyeti:** Depo açılacak ilin çevresindeki belirlenmiş dağıtım noktalarına yapılan sevkiyatların mikro dağıtım maliyetini kapsamaktadır. Bu maliyet, her bir ile yapılan teslimatların tonajı, dağıtım yapılan mesafeler ve taşımacılık maliyet katsayıları dikkate alınarak hesaplanmaktadır. Toplam dağıtım maliyeti, dağıtım ağı içindeki rotaların etkinliğini artırmaya yönelik önemli bir kriterdir.
- **Toplam Depolama Maliyeti:** Depo açılan ildeki lojistik işlemlerle ilgili olarak yıllık oluşan maliyetleri ifade eder. Bu maliyet, ürünlerin kabulü, depolanması, sipariş üzerine hazırlanması ve sevkiyata hazır hale getirilmesi gibi işlemlerden kaynaklanır. Özellikle büyük tonajlarda dağıtım yapılan depolarda, bu işlemlerin verimliliği maliyetlerin düşürülmesinde önemli bir etkidir.
- **Kira Maliyeti:** Depo açılacak ildeki depo alanının yıllık kira maliyetlerini içerir. Bu maliyet, depo lokasyonunun stratejik avantajları, kira oranları ve ihtiyaç duyulan alanın büyüklüğüne göre değişiklik göstermektedir. Depo kira maliyeti, doğru lokasyon seçimiyle minimize edilebilecek önemli bir bileşendir.

Amaç fonksiyonu, yukarıdaki tüm bileşenleri dikkate alarak, minimum toplam maliyetle maksimum verimliliği sağlayan bir optimizasyon çözümü sunar. Bu yaklaşım, dağıtım ağı içindeki lojistik süreçlerin bütünsel bir şekilde analiz edilmesini ve şirketin

gelecekteki lojistik performansını artıracak stratejik kararların alınmasını sağlar. Amaç Fonksiyonunun özet hali ve alt toplamaları Şekil 6.20’de gösterilmiştir.

AMAÇ FONKSİYONU	
Toplam Besleme Maliyeti	62.849.043
Toplam Dağıtım Maliyeti	176.145.947
Toplam Depo Maliyeti	184.602.206
Toplam Kira	min 140.007.686
Toplam Maliyet	563.604.883
Amaç Fonksiyonu	563.604.883

Şekil 6.20. Dağıtım Operasyonu Maliyet Kalemleri

Optimizasyon modelinde, toplam maliyeti oluşturan bileşenler Toplam Besleme Maliyeti, Toplam Dağıtım Maliyeti, Toplam Depo Maliyeti ve Toplam Kira Maliyeti olarak ayrıştırılmış ve özetlenmiştir. Excel Solver modelinde bu tablo üzerinden özet kıyaslamalar yapılabilecektir.

Ek Bilgi: Dağıtım Ağı Algoritması 81x81 İller arası mesafeler matrisi üzerinden çalışır.

[illegible]

Şekil 6.21. İller Arası Mesafe Matrisi


Mikro dağıtım maliyetlerinin hesaplanmasında, Türkiye Cumhuriyeti Karayolları Genel Müdürlüğü'nün (TCK KGM) web sitesinde yayımlanan Şekil 6.21'de gösterilen İller Arası Mesafe Matrisi (01.01.2021 tarihli güncel veri) kullanılmıştır. Bu matris, Türkiye'deki tüm iller arasındaki karayolu mesafelerini kilometre bazında içermektedir.

Çalışmada, her ilin dağıtım yapacağı diğer illere olan mesafeleri bu matristen alınarak, mikro dağıtım maliyetlerinin hesaplanmasında temel veri kaynağı olarak kullanılmıştır. Bu yaklaşım, mesafeye dayalı maliyet hesaplamalarının doğruluğunu artırmakta ve optimizasyon modelinin gerçekçi sonuçlar üretmesine katkı sağlamaktadır (Kaynak: TCK Karayolları Genel Müdürlüğü).

6.3.1.2. Model Kısıtları ve Değişkenleri;

Bu bölümde, optimizasyon modelinde kullanılan kısıtlar ve değişkenler detaylı olarak açıklanmaktadır. Şekil 6.22’de gösterildiği üzere modelin temel kısıtları, amaç fonksiyonu ve değişkenleri yer almaktadır.

OpenSolver eklentisi ile modelin yapılandırma süreci gösterilmektedir. "Objective Cell" kısmında toplam maliyetin minimize edilmesi hedeflenmiş, "Variable Cells" kısmında modelin çözüm sürecinde değiştirilen karar değişkenleri tanımlanmış, "Constraints" kısmında ise yukarıda belirtilen kısıtlar modele eklenmiştir. Çözüm algoritması olarak CBC Solver Engine kullanılmış ve bu parametreler ışığında dağıtım ağı optimizasyonu gerçekleştirilmiştir.



Şekil 6.22. OpenSolver Model Detayları

KISITLAR-1	
Toplam Arz	173.578
Toplam Talep	$\geq$ 173.578
Açılan Depo	24
Açılma Sınırı	$\leq$ 24

Şekil 6.23. Kısıt Gösterimi

Şekil 6.23'te modelin ilk kısıtları olan Toplam Arz, Toplam Talep ve Açılan Depo Sınır Kısıtları gösterilmiş olup aşağıda detayları açıklanmıştır.

- **Toplam Arz Kısıtı:** Türkiye genelindeki tüm illerin yıllık toplam satış tonajının karşılanmasını sağlayan kısıttır. Bu değer, 2023 yılı için toplamda 173 bin ton olarak belirlenmiştir. Bu kısıt, modelin tüm talepleri eksiksiz bir şekilde karşılamasını zorunlu kılar.
- **Depo Açma Kısıtı:** Dağıtım ağı optimizasyonu sonucunda açılabilir maksimum depo sayısını belirleyen kısıttır. 2023 yılı mevcut durumda, en fazla 24 depo açılması öngörülmüştür. Bu kısıt, maliyetlerin kontrol edilmesini ve depo sayısının belirli bir sınır içinde tutulmasını sağlar. Farklı senaryolarda bu kısıt değiştirilebilir.

TÜM İLLERİN TALEBİ KARŞILANMALIDIR									
DEPO AÇILMA KARARI VERİLEN İLLERDEN MAKS ÇIKIŞ İLİ SAYISI									
İL BAZLI TONAJ KARŞILANMA KISITI									
AG	AH	AI	AJ	AK	AL	AM	AN	AO	AP
KISITLAR-2									
Depo	Depo mu?	*	Beslenme Say	Bes. Kısıtı	Çıkış Sayısı	Çık. Kısıtı	Top. Tonaj	İl Talebi	Kurulum Maliyeti
ADANA	0	1	1	1	0	0	8.013	8.013	8.012.964
ADYAMAN	0	1	1	1	0	0	871	871	871.239
AFYONKARAHİSAR	1	1	1	1	3	10	1.540	1.540	1.539.944
AĞRI	0	1	1	1	0	0	246	246	246.177
AMASYA	0	1	1	1	0	0	8	8	8.157
ANKARA	0	1	1	1	0	0	7.273	7.273	7.272.662
ANTALYA	0	1	1	1	0	0	6.735	6.735	6.735.042
ARTVİN	0	1	1	1	0	0	84	84	84.475
AYDIN	1	1	1	1	2	10	3.081	3.081	3.080.979
BALIKESİR	1	1	1	1	2	10	3.431	3.431	3.431.115
BİLECEK	1	1	1	1	7	10	54	54	53.743
BİNGÖL	0	1	1	1	0	0	10	10	10.195
BITLİS	0	1	1	1	0	0	27	27	26.663
BOLU	0	1	1	1	0	0	313	313	313.166
BURDUR	1	1	1	1	3	10	199	199	199.328
BURSA	0	1	1	1	0	0	6.054	6.054	6.053.554
ÇANAKKALE	0	1	1	1	0	0	876	876	875.983
ÇANKIRI	0	1	1	1	0	0	316	316	315.554
ÇORUM	0	1	1	1	0	0	27	27	26.748
DENİZLİ	1	1	1	1	1	10	2.455	2.455	2.455.281
DIYARBAKIR	0	1	1	1	0	0	7.801	7.801	7.801.441
EDİRNE	0	1	1	1	0	0	1.132	1.132	1.131.732
ELAZIĞ	0	1	1	1	0	0	1.598	1.598	1.597.581
ERZİNCAN	0	1	1	1	0	0	604	604	604.439
ERZURUM	1	1	1	1	5	10	4.085	4.085	4.085.263

Şekil 6.24. İl Bazlı Kısıtların Gösterimi

Şekilde 6.24'te İl Bazlı Kısıtların Gösterimi yapılmış olup detayları aşağıdaki maddelerde belirtilmiştir.

- Tüm İllerin Beslenme Kısıtı (İl Bazlı): Her ilin talebi, belirli bir depo veya fabrikadan ürün sevkiyatı ile eksiksiz bir şekilde karşılanmalıdır.
- Depodan Çıkış İli Kısıtı: Bir depodan çıkış yapılarak dağıtım gerçekleştirilebilecek maksimum il sayısını sınırlar. Bu kısıt, depo kapasitesini ve dağıtımın etkinliğini göz önünde bulundurarak, her bir deponun yalnızca belirli sayıda çevre ile hizmet sunmasını sağlar. Bu şekilde, kaynakların aşırı kullanımı engellenir ve dağıtım rotaları daha verimli hale getirilir.
- İl Bazlı Sipariş Karşılama Kısıtı: Her ilin yıllık talebi eksiksiz bir şekilde karşılanmalıdır. Bu kısıt, her ilin belirlenen yıllık talep miktarının optimize edilmiş dağıtım ağı tarafından sağlanmasını zorunlu kılar. Örneğin, iller için belirtilen tonaj miktarları (örneğin, 173.578 ton) ilgili depo veya lojistik merkezlerinden karşılanmalıdır.

Şekil 6.25. Network KM Dağıtım Kısıtı

Excel ekran görüntüsü: "Talep Tahmini ve Dağıtım Ağı Optimizasyonu v4.5 - Excel".

Formül: $=EĞER(F5<=G$3,1,0)$

Kısıt: BİRBİRİNE 300 KM'DEN FAZLA UZAK OLAN İL DEN İLE DAĞITIM YAPILMA KISITI

	Birleşik	Çıkış	Çıkış İl	Varış	Varış İl	Km	Network	Varış İli Talebi (Ton)	Dağıtım?	Dağıtım Yap	Depo Aç
837 9-45	9	AYDIN	45	MANİSA	155	1	91	0	1	-	-
838 9-48	9	AYDIN	48	MUĞLA	98	1	5.407	1	1	-	-
839 9-64	9	AYDIN	64	UŞAK	273	1	534	0	1	-	-
840 9-9	9	AYDIN	9	AYDIN	40,573	1	3.081	1	1	1	1
841 10-1	10	BALIKESİR	1	ADANA	903	0	8.013	-	-	-	-
842 10-12	10	BALIKESİR	12	BİNGÖL	1414	0	10	-	-	-	-
843 10-13	10	BALIKESİR	13	BİTLİS	1604	0	27	-	-	-	-
844 10-14	10	BALIKESİR	14	BOLU	422	0	313	-	-	-	-
845 10-15	10	BALIKESİR	15	BURDUR	395	0	199	-	-	-	-
846 10-18	10	BALIKESİR	18	ÇANKIRI	655	0	316	-	-	-	-

Şekil 6.25. Network KM Dağıtım Kısıtı

- İller Arası Dağıtım Mesafesi Kısıtı: Bu kısıt, mikro dağıtım operasyonları için geçerlidir ve maksimum mesafe sınırı 300 kilometre olarak belirlenmiştir. 300 kilometreyi aşan mesafelerde, dağıtım sonrası depoya dönüş süresiyle birlikte takograf süre kısıtlarına takılma riski bulunmaktadır. Bu durum, operasyonlarda çift şoför uygulamasını zorunlu kılmakta ve ek maliyetler getirmektedir. Söz konusu kısıt, bu tür maliyetlerin minimize edilmesi ve lojistik operasyonların etkin bir şekilde yönetilmesi amacıyla modelde tanımlanmıştır. Şekil 6.25'te Excel'deki modelde Network kısıtının

nasıl yapıldığı gösterilmiştir.

6.3.2. Matematiksel Model:

Model, iller arası mesafe ve dağıtım kararları ile ilişkilendirilerek aşağıdaki şekilde tanımlanmıştır.

- Karar Değişkenleri:

x_{ij} : Depo i 'den şehir j 'ye yapılan dağıtım miktarı (ton)

y_i : Eğer i 'de depo açılırsa 1, aksi takdirde 0 (binary değişken)

z_{ij} : Eğer i 'den j 'ye dağıtım yapılırsa 1, aksi takdirde 0 (binary değişken)

- Amaç Fonksiyonu:

Toplam operasyon maliyetini minimize etmek için (6.1) denklemini kullanılır.

$$\min Z = \sum_i \sum_j C_{ij} x_{ij} + \sum_i F_i Y_i + \sum_i H_i Y_i + \sum_i \sum_j D_{ij} Z_{ij} \quad (6.1)$$

Burada:

C_{ij} : i deposundan j şehrine yapılan taşımacılığın birim maliyeti

F_i : i 'de bir depo açmanın sabit kira maliyeti

H_i : i 'de depo açılırsa oluşan yıllık elleçleme maliyeti

D_{ij} : i 'den j 'ye yapılan dağıtımın birim maliyeti

Model kısıtları ise aşağıdaki şekilde tanımlanmıştır.

- Tüm Şehirlerin Talebinin Karşıllanması:

$$\sum_i x_{ij} = T_j, \quad \forall j \quad (6.2)$$

Denklem (6.2)'de T_j , şehir j 'nin yıllık talebini ifade eder.

- Depo Kapasite Kısıtı:

$$\sum_j x_{ij} \leq K_i y_i, \quad \forall i \quad (6.3)$$

Denklem (6.3)'te K_i , depo i 'nin maksimum kapasitesidir. Depo açılmazsa ($y_i = 0$), oradan sevkiyat yapılamaz.

- Dağıtım Yapılıp Yapılmadığının Belirtilmesi:

$$x_{ij} \leq M_{z_{ij}}, \quad \forall i, j \quad (6.4)$$

Denklem (6.4)'te M büyük bir pozitif sabit olup, X_{ij} 'nin pozitif olabilmesi için $Z_{ij} = 1$ olması gerekmektedir.

- Depo Açma Kısıtı:

$$\sum_i y_i \leq N_{max} \quad (6.5)$$

Denklem (6.5)'te N_{max} , açılabilir maksimum depo sayısını ifade eder.

- İller Arası Maksimum Dağıtım Mesafesi Kısıtı Denklem (6.6)'da gösterildiği gibidir.

$$d_{ij} \cdot z_{ij} \leq 300, \quad \forall i, j \quad (6.6)$$

Burada:

d_{ij} , i ve j arasındaki mesafeyi ifade eder.

Eğer $z_{ij} = 1$ (dağıtım gerçekleşiyor), o zaman mesafe 300 km'yi aşamaz..

Eğer $d_{ij} > 300$ ise, o noktalar arasında dağıtım yapılamaz.

- Karar Değişkenlerinin Tanımlanması:

$$x_{ij} \geq 0, \quad y_i \in \{0, 1\}, \quad z_{ij} \in \{0, 1\} \quad (6.7)$$

Denklem (6.7)'de gösterilen bu güncellenmiş model, 300 km mesafe kısıtı ile uzun mesafeli dağıtımları sınırlandırarak, lojistik operasyonların daha verimli ve düzenli bir şekilde planlanmasını sağlamaktadır.

6.3.3. Optimizasyon Modeli Maliyet Kalemleri Kurgusu:

Bu kısımda Optimizasyon Modelinde kullanılacak olan yapının Excel'deki kurgusu detaylı şekilde açıklanmıştır. Örneğin Dağıtım Maliyetini oluşturan unsurlar, İşçilik Giderleri ve İl Bazındaki değişkenliği oluşturan unsurlar vb. detaylar açıklanmıştır. Şekil 6.26'da modelin Excel'deki tasarımı gösterilmiştir.

Şekil 6.26. Dağıtım Karar Modeli

Besleme maliyeti, sefer tarifesı üzerinden çalışıldığı için iller arasındaki mesafeden bağımsız olarak, yıllık taşınacak ürün miktarına ve bir TIR sefer maliyetine bağılı olarak hesaplanmıştır. Bu maliyet, her hedef il için yıllık toplam tonajın, bir TIR'ın taşıma kapasitesine bölünerek yıllık sefer sayısının bulunması ve bu sefer sayısının sefer başına maliyetle çarpılmasıyla elde edilmektedir. Denklem (6.8)'te besleme maliyetinin formülü gösterilmiştir.

$$\text{Besleme Maliyeti} = \text{Tır Sefer Maliyeti} * \text{Yıllık Sefer Sayısı} \quad (6.8)$$

Örneğin, bir ilin yıllık talebi 3.431 ton ve TIR sefer maliyeti 12.400 TL olduğunda, yıllık sefer sayısı bu talebin TIR kapasitesine bölünmesiyle hesaplanır ve toplam besleme maliyeti bu iki değerin çarpımı ile bulunur. Şekil 6.27'de gösterildiği üzere her ilin bu şekilde hesaplanmış besleme maliyetleri detaylı olarak gösterilmiştir.

[illegible]

Şekil 6.27. Besleme Maliyet Model Kurgusu

Mikro dağıtım maliyeti, iller arası taşımacılığın talep tonajı ve mesafeye bağlı olarak hesaplandığı bir maliyet bileşenidir. Bu maliyet, network durumu (1 veya 0), iki il arasındaki mesafe (km), yıllık talep edilen tonaj ve birim mikro dağıtım maliyet katsayısına göre hesaplanmaktadır. Denklem (6.9)'da formül yapısı gösterilmiştir.

$$\text{Dağıtım Maliyeti} = \text{Network (1, 0)} * \text{Mesafe (KM)} * \text{Talep Tonajı} * \text{Birim Mikro Dağıtım Maliyeti} \quad (6.9)$$

Bu hesaplama, dağıtım ağında aktif olan rotalar için geçerlidir (network = 1). Örneğin, bir ilin talep tonajı 3.431 ton, mesafesi 40.573 km ve birim mikro dağıtım maliyeti 15 TL/Ton*KM olduğunda, bu değerlerin çarpımı sonucunda mikro dağıtım maliyeti hesaplanır. Şekilde 6.28’de her il için bu yöntemle göre hesaplanmış mikro dağıtım maliyetleri detaylı şekilde gösterilmiştir. Bu yaklaşım, dağıtım ağının toplam maliyet üzerindeki etkisini doğru bir şekilde değerlendirmek için kullanılmıştır.

Yatırım Hesaplamaları

Talep Tahmini ve Dağılımı Ağı Optimizasyonu v4.3 - Excel

Formül: $\text{DAĞITIM MALİYET: KM} * \text{NETWORK (L6)} * \text{YILLIK TONAJ} + \text{DAĞITIM TL (MİKRO DAĞITIM)}$

	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S	T	U	V	W	X	Y	Z	AA	AB	AC	AD	AE
1																													
2																													
3																													
4																													
5																													
6																													
7																													
8																													
9																													
10																													
11																													
12																													
13																													
14																													
15																													
16																													

DAĞITIM MALİYET: KM * NETWORK (L6) * YILLIK TONAJ + DAĞITIM TL (MİKRO DAĞITIM)

GÖSTERGELER

MALİYET KATSAYILARI

	DAĞITIM TL (TL/TON/KM)	15,00
Etileleme TL	1000,00	

KISITLAR-1

	Toplam Arz	173.578
Toplam Talep	173.578	

Açılan Depo: 24
Açılma Sınırı: 24

Şekil 6.28. Dağıtım Kararı ve Maliyet Kurgusu

Şekil 6.29’da Elleçleme Maliyetinin Excel’deki kurgu ve tasarımı gösterilmiştir.

Çıkış İl	Varış Varış İl	Km	Network	Varış İli Talebi (Ton)	Dağıtım?	Dağıtım Yap	Depo Aç	Açılan Deponun Tonajı	İşçilik	Elleçleme Maliyeti
5	BALIKESİR	10	BALIKESİR	40.573	1	1	1	3.431	1219	4.183.816
6	BALIKESİR	11	BİLEÇİK	246	1	0	-	-	1219	-
7	BALIKESİR	16	BURSA	151	1	0	-	-	1219	-
8	BALIKESİR	17	ÇANAKKALE	191	1	0	-	-	1219	-
9	BALIKESİR	20	DENİZLİ	287	1	0	-	-	1219	-
10	BALIKESİR	35	İZMİR	176	1	0	-	-	1219	-
11	BALIKESİR	41	KOCAELİ	279	1	0	-	-	1219	-
12	BALIKESİR	43	KUTAHYA	228	1	0	-	-	1219	-
13	BALIKESİR	45	MANİSA	141	1	0	-	-	1219	-
14	BALIKESİR	64	UŞAK	223	1	0	-	-	1219	-
15	BALIKESİR	77	YALOVA	216	1	0	-	-	1219	-
16	BALIKESİR	9	AYDIN	296	1	0	-	-	1219	-
17	ADANA	1	ADANA	40.573	1	0	-	-	1219	-
18	BİLEÇİK	10	BALIKESİR	245	1	0	-	-	1134	-
19	BİLEÇİK	11	BİLEÇİK	40.573	1	0	-	-	1134	-
20	BİLEÇİK	14	BOLU	212	1	0	-	-	1134	-
21	BİLEÇİK	16	BURSA	94	1	0	-	-	1134	-
22	BİLEÇİK	26	ESKİŞEHİR	83	1	0	-	-	1134	-
23	BİLEÇİK	3	AFYONKARAHİSAR	212	1	0	-	-	1134	-

Şekil 6.29. Elleçleme Kararı ve Maliyet Kurgusu

Elleçleme maliyeti, depo açılan ilin yıllık toplam dağıtım tonajı için harcanan işçilik giderlerini ifade eder. Bu maliyet, depo açma kararı (1 veya 0) ile ilişkilendirilmiş olup, yalnızca aktif depolar için hesaplanmaktadır. Denklem (6.10)’da yıllık toplam tonaj ve depo iline özgü işçilik katsayısı temel alınarak hesaplama yapılmaktadır.

$$\text{Elleçleme Maliyeti} = \text{Açılan Depoya Atanan Yıllık Toplam Tonaj} * \text{Depo İlinin İşçilik Katsayısı} * \text{Depo Açma Kararı (1,0)} \quad (6.10)$$

Örneğin, bir depoya atanan toplam tonaj 3.431 ton, işçilik katsayısı 1.219 TL/Ton, ve depo açma kararı 1 olduğunda yıllık maliyet 4.183.816 TL olur.

Şekil 6.30’da tüm iller için bu hesaplamanın detayları gösterilmekte ve elleçleme maliyetleri optimize edilmiş sonuçlarla birlikte sunulmaktadır. Bu maliyet, toplam operasyonel giderlerin önemli bir bileşenidir ve modelde kritik bir rol oynamaktadır.

- İşçilik Gideri Varsayımı:

İllerin işçilik maliyetlerini belirlemek için bir dizi ekonomik ve sosyoekonomik göstergelere dayalı varsayımlar kullanılmıştır. Bu göstergeler, illerin gelişmişlik düzeylerini yansıtarak maliyetlerin tahmin edilmesine temel oluşturmuştur. Kullanılan göstergeler şunlardır.

Talep Tahmini ve Değerlendirme v4.8 - Excel										
İLLERİN GELİŞİMİŞLİK DÜZEYİ VARSAYIMI İÇİN BAZ ALINAN İNDEKSLER										
GEÇMİŞ ÇALIŞMA REFERANSLARI										
İLİN TAHMİNİ İŞÇİLİK MALİYETİ										
A	B	C	D	E	F	G	H	I	J	K
1	Plaka	Şehirler	Konut Satış	GSYH	SEGE	ORT	ORT SIRA	TL/TON	KATSAYI	TL/TON
2	34	İSTANBUL	1	2	1	1,33	1	0,917	1,40	1400
3	6	ANKARA	2	4	2	2,67	2	0,829	1,39	1389
4	35	İZMİR	3	5	3	3,67	3		1,38	1379
5	41	KOCAELİ	10	1	4	5,00	4		1,37	1368
6	7	ANTALYA	4	10	5	6,33	5	0,817	1,36	1358
7	16	BURSA	5	9	6	6,67	6		1,35	1347
8	59	TEKİRDAĞ	11	3	9	7,67	7	1,166	1,34	1336
9	48	MUĞLA	21	12	8	13,67	8	0,688	1,33	1326
10	26	ESKİŞEHİR	20	14	7	13,67	9		1,32	1315
11	77	YALOVA	23	8	12	14,33	10		1,30	1304
12	33	MERSİN	6	18	25	16,33	11	0,880	1,29	1294
13	54	SAKARYA	18	20	11	16,33	12		1,28	1283
14	38	KAYSERİ	9	27	17	17,67	13	0,547	1,27	1273
15	42	KONYA	8	31	14	17,67	14	0,655	1,26	1262
16	20	DENİZLİ	22	21	10	17,67	15	1,160	1,25	1251

Şekil 6.30. İşçilik Maliyetleri Kurgusu

- İl Bazlı Yıllık Konut Satışları: İllerin yıllık konut satış miktarları, ekonomik canlılığı ve iş gücü talebini yansıttığı için önemli bir ölçüt olarak kullanılmıştır (TÜİK, 2024).
- Gayri Safi Yurtiçi Hasıla (GSYH): İllerin ekonomik büyüklüğünü ve sektörel çeşitliliğini ölçen GSYH değerleri, iş gücü maliyetlerinin belirlenmesinde kritik bir rol oynamıştır (TÜİK, 2024).
- Bakanlık SEGE Raporu: Türkiye İstatistik Kurumu ve Bakanlık tarafından hazırlanan Sosyo-Ekonomik Gelişmişlik Endeksi (SEGE) verileri, illerin genel gelişmişlik düzeylerini objektif bir şekilde sıralamak için kullanılmıştır (Sanayi Bakanlığı, SEGE 2017-2022).

Bu veriler bir araya getirilerek, iller gelişmişlik düzeyine göre sıralanmış ve en gelişmiş iller, iş gücü maliyetlerinin en yüksek olduğu şehirler olarak kabul edilmiştir. Şirketin depo konumlarının yer aldığı iller için mevcut maliyet verileri, diğer illerdeki işçilik maliyetlerinin tahmin edilmesinde referans olarak kullanılmıştır. Böylece, sıralamadaki gelişmişlik düzeylerine göre illere işçilik katsayıları atanmış ve ton başına işçilik maliyetleri hesaplanmıştır.

Bu yöntem, hem mevcut verilere dayalı olarak hem de gelişmişlik sırasına göre tahmin yapılarak, işçilik maliyetlerinin tutarlı ve gerçekçi bir şekilde modellenmesini sağlamıştır. Görselde, tüm iller için sıralama ve işçilik maliyet katsayıları detaylı olarak sunulmuştur.

- Kira Maliyetleri:

Kira maliyetleri, depoların yıllık tonajlarına dayalı olarak ihtiyaç duyulan depo alanı ve ilgili ilin ticari kira fiyatlarına göre hesaplanmıştır. Hesaplama süreci şu şekilde gerçekleştirilmiştir:

- Depo Alanı Hesabı:

Her depo için gereken m² alan, yıllık taşınacak toplam tonaj ve bir deponun 50 günlük Stok Devir Hızı (SDH) ile çalışacağı varsayımına dayalı olarak hesaplanmıştır. Bu yaklaşım, her deponun belirlenen süre içinde stokları devir hızına uygun şekilde ihtiyaç duyduğu alanı belirlemiştir. Yani, deponun 50 günlük stokları rahatça barındırabilecek kapasitede olması esas alınmıştır.

- Ticari Kira Fiyatları:

İller bazında hesaplanan ihtiyaç duyulan depo alanı, pazar araştırmalarıyla belirlenen ticari kiralık m² fiyatları ile çarpılmıştır. Bu fiyatlar, ticari gayrimenkul pazarında güvenilir bir kaynak olan Endeksa platformundan elde edilmiştir. Endeksa üzerinden her il için m² başına ticari kira fiyatları dikkate alınarak, toplam kira maliyetleri hesaplanmıştır (URL-2, 2024). Bu bilgilere dayanarak Kira Maliyetinin nasıl hesaplandığı Denklem (6.11)'deki formül üzerinden gösterilmiştir.


$$\text{Kira Maliyeti} = \text{Depo m2 İhtiyacı} * \text{Kiralık m2 Fiyatı} \quad (6.11)$$

	Çıkış İli	Varış	Varış İli	Km	Network	Varış İli Talebi (Ton)	Dağıtım?	Dağıtım Yap	Depo Ap	Depo m2	TL/m2	Kira Maliyeti
4	BALIKESİR	10	BALIKESİR	40.573	1	3.431	1	1	1	1.625	156	3.041.216
5	BALIKESİR	11	BİLEÇİK	246	1	54	0	-	-	-	156	0
6	BALIKESİR	16	BURSA	151	1	6.054	0	-	-	-	156	0
7	BALIKESİR	17	ÇANAKKALE	191	1	876	1	1	-	415	156	776.440
8	BALIKESİR	20	DENİZLİ	287	1	2.455	0	-	-	-	156	0
9	BALIKESİR	35	İZMİR	176	1	13.359	0	-	-	-	156	0
10	BALIKESİR	41	KOCAELİ	279	1	1.847	0	-	-	-	156	0
11	BALIKESİR	43	KÜTAHYA	228	1	728	0	-	-	-	156	0
12	BALIKESİR	45	MANİSA	141	1	91	0	-	-	-	156	0
13	BALIKESİR	64	UŞAK	223	1	534	0	-	-	-	156	0
14	BALIKESİR	77	YALOVA	216	1	47	0	-	-	-	156	0
15	BALIKESİR	9	AYDIN	296	1	3.081	0	-	-	-	156	0
16	BALIKESİR	1	ADANA	40.573	1	8.013	1	1	1	3.794	201	9.151.169
17	BİLEÇİK	10	BALIKESİR	245	1	3.431	0	-	-	-	83	0
18	BİLEÇİK	11	BİLEÇİK	40.573	1	54	0	-	-	-	83	0
19	BİLEÇİK	14	BOLU	212	1	313	0	-	-	-	83	0
20	BİLEÇİK	16	BURSA	94	1	6.054	0	-	-	-	83	0
21	BİLEÇİK	26	ESKİŞEHİR	83	1	87	0	-	-	-	83	0
22	BİLEÇİK	3	AFYONKARAHİSAR	212	1	1.540	0	-	-	-	83	0

Şekil 6.31. Depo Alan İhtiyacı ve Kira Maliyeti Kurgusu

Şekilde 6.31'de depo açılan il bazlı Kira Maliyetlerinin hesaplama modeli gösterilmiştir.

Örneğin, Alan İhtiyacı $1.625 \text{ m}^2 * 156 \text{ TL/m}^2 \text{ Kira} = 3.041.216 \text{ TL/YIL}$



Şekil 6.32. Endeksa Gayrimenkul Birim Kiraları (Endeksa)

Şekil 6.32’de her ilin kira maliyetlerinin hesaplanış süreci ve Endeksa platformundan alınan m^2 fiyatları detaylı şekilde sunulmuştur. Bu yöntem, depoların operasyonel ihtiyaçlarına uygun olarak maliyetlerin gerçekçi bir şekilde modellenmesini sağlamıştır (URL-2, 2024).

Plaka	Şehirler	TL/m2	Şehirler	Ticari	Depo	Ort. Değer	Amortisman	Getiri	Yıllık Değişim	*	*	*
48	MUĞLA	299	Muğla	299	159	31.665 ₺	%6,47	%44,63	15 yıl	%5,79	%57,07	
34	İSTANBUL	277	İstanbul	277	197	41.252 ₺	%6,90	%66,76	14 yıl	%5,56	%56,96	
41	KOCAELİ	224	Kocaeli	224	233	53.839 ₺	%6,85	%67,47	18 yıl	%5,08	%41,54	
35	İZMİR	215	İzmir	215	132	25.988 ₺	%7,94	%53,53	15 yıl	%6,45	%70,32	
6	ANKARA	214	Ankara	214	102	31.003 ₺	%6,71	%58,86	20 yıl	%5,78	%57,83	
7	ANTALYA	202	Antalya	202	88	27.421 ₺	%8,00	%62,51	12 yıl	%5,64	%61,48	
1	ADANA	201	Adana	201	99	33.232 ₺	%6,45	%70,32	15 yıl	%6,89	%64,20	
21	DIYARBAKIR	186	Diyanbakır	186	73	27.530 ₺	%5,85	%50,88	17 yıl	%7,66	%45,29	
77	YALOVA	184	Yalova	184	98	33.143 ₺	%6,50	%88,96	15 yıl	%6,50	%88,96	
54	SAKARYA	174	Sakarya	174	105	31.257 ₺						
33	MERSİN	171	Mersin	171	90	20.574 ₺						
16	BURSA	167	Bursa	167	104	26.774 ₺						
22	EDİRNE	165	Edirne	165	115	24.148 ₺						
9	AYDIN	164	Aydın	164	101	24.938 ₺						
42	KONYA	160	Konya	160	82	25.569 ₺						
31	HATAY	157	Hatay	157	92	24.079 ₺						
45	MANİSA	157	Manisa	157	99	32.519 ₺						

Şekil 6.33. İl Bazlı Depo Kira Maliyetleri

Şekil 6.33’te Excel’in Ana Veri kısmında tüm illerin Ticari Kira birim maliyetleri gösterilmiştir. Optimizasyon modelinde ise sadece depo açılan illerin maliyetleri gösterilmektedir. Ancak Optimizasyon modeli tüm illerin maliyetlerini sürece dahil

ederek en uygun olanları kullanıcı ara yüzünde göstermektedir. Böylelikle daha kolay bir kullanım ve yalın bakış sağlanması hedeflenmiştir.

Modelin temel amacı, Toplam Maliyeti oluşturan bileşenleri minimize etmektir. Toplam maliyet, kira maliyeti, besleme maliyeti, elleçleme maliyeti ve dağıtım maliyeti gibi alt kalemlerin toplamından oluşmakta olup, modelin minimize etmeye çalıştığı temel hedeftir. Aşağıda bulunan Şekil 6.34'te toplam maliyet ve bunu oluşturan alt kırılım toplamları gösterilmiştir.

Şu anda mevcut durumu temsil eden toplam maliyet 732.598.222 TL'dir ve bu rakam, 2023 yılının kapanış değeridir. Devam eden kısımlarda, bu maliyetin optimizasyon süreci ile nasıl minimize edildiği detaylı olarak açıklanacaktır.

AB3	C	D	E	F	G	H	I	J	K	X	Y	Z	AA	AB	AC
1															
2															
3															
4															
5															
6															
7															
8															
9															
10															
11															
12															
13															
14															
15															
16															
17															
18															
19															
20															
21															
22															
23															
24															
25															
26															
27															
28															
29															
30															
31															
32															
33															
34															
35															
36															
37															
38															
39															
40															
41															
42															
43															
44															
45															
46															
47															
48															
49															
50															
51															
52															
53															
54															
55															
56															
57															
58															
59															
60															
61															
62															
63															
64															
65															
66															
67															
68															
69															
70															
71															
72															
73															
74															
75															
76															
77															
78															
79															
80															
81															
82															
83															
84															
85															
86															
87															
88															
89															
90															
91															
92															
93															
94															
95															
96															
97															
98															
99															
100															

Şekil 6.34. Dağıtım Ağı Kararına Göre Toplam Maliyetler

Denklem (6.12)'de Toplam Maliyetin formülü yapıları gösterilmiştir.

$$\text{Toplam Maliyet} = \text{Kira Maliyeti} + \text{Besleme Maliyeti} + \text{Elleçleme Maliyeti} + \text{Dağıtım Maliyeti} \quad (6.12)$$

6.3.4. Mevcut Durum Dağıtım Ağı ve Maliyetleri

2023 yılı itibarıyla şirketin dağıtım ağı ve depo yapısı, aşağıdaki haritada gösterildiği gibi Türkiye genelinde 24 depo ile faaliyet göstermektedir. Bu yapıda, her bir depo belirli bölgelere hizmet vermekte ve mikro dağıtım, besleme, kira ve elleçleme maliyetlerinden

oluşan toplam operasyon maliyetleri ortaya çıkmaktadır.

2023 yılı toplam operasyon maliyeti 732.598.529 TL olarak hesaplanmıştır. Bu rakam, mevcut durumdaki dağıtım ağının tüm lojistik giderlerini temsil etmekte olup, şirketin maliyet azaltımı ve süreç iyileştirmesi için optimizasyon ihtiyacını açıkça ortaya koymaktadır. Şekil 6.35'te gösterilen haritada, mevcut depo konumları ve bu depoların hizmet verdiği bölgeler detaylı bir şekilde sunulmuştur. Devam eden analizlerde, bu yapının maliyet etkinliği ve iyileştirme potansiyeli detaylı olarak değerlendirilecektir.



Şekil 6.35. Mevcut Durum Bölgesel Depolar Dağıtım Haritası


2023 yılı mevcut dağıtım ağı incelendiğinde, toplam operasyon maliyetinin 732.598.529 TL olduğu görülmektedir. Bu maliyet, dört ana bileşenden oluşmaktadır: Besleme Maliyeti 186.645.978 TL, Dağıtım Maliyeti 159.893.781 TL, Elleçleme Maliyeti 209.224.935 TL ve Kira & Depolama Maliyeti 176.833.529 TL. Toplamda 24 depo ile faaliyet gösteren mevcut yapı, operasyonel süreçlerin yüksek maliyetle sürdürüldüğünü ortaya koymaktadır. Bu durum, maliyetlerin optimize edilmesi ve verimliliğin artırılması için önemli bir potansiyel sunmaktadır. Tablo 6.1'de Mevcut Durum Maliyetleri ve alt kırımlarını verilmiştir.

Tablo 6.1. 2023 Mevcut Durum Maliyetleri

Kapsam	2023-Mevcut
Toplam Tonaj	173.578
BESLEME	186.645.978
DAĞITIM	₺159.893.781
ELLEÇLEME	₺209.224.935
KİRA&DEPOLAMA	₺176.833.529
TOPLAM MALİYET	₺732.598.222
Depo Sayısı	24
Açılan Depo	-
Kapanan Depo	-
Avantaj	-
TL/TON	₺4.221

6.3.5. 2023 Mevcut Dağıtım Modelinin Optimize Edilmesi (Senaryo-1)


Bu senaryoda, 2023 yılı mevcut dağıtım ağı ve maliyet verileri, Excel OpenSolver eklentisi kullanılarak optimize edilmiştir. Çözüm sürecinde, CBC (Coin-or branch and cut) çözücüsü kullanılmış ve modelin amaç fonksiyonu olarak toplam operasyon maliyetinin minimize edilmesi hedeflenmiştir. Şekilde 6.36’da gösterildiği gibi mevcut durum Optimizasyon için uygun hale getirilmiştir.



Şekil 6.36. 2023 Mevcut Durumun Optimizasyon İçin Hazırlanması


Model, mevcut dağıtım ağı yapısını ve maliyet bileşenlerini dikkate alarak optimize edilmiştir. Bu süreçte, depo açma kısıtları, toplam arz ve talep dengesi gibi parametreler ile besleme, elleçleme, dağıtım ve kira maliyetleri minimize edilmiştir. OpenSolver'ın esnek kısıt tanımlama ve değişken belirleme özellikleri sayesinde, model farklı senaryolar altında optimize edilebilmiş ve toplam maliyetin düşürülmesi için öneriler sunulmuştur.

Görselde, kullanılan OpenSolver ayarları, tanımlanan kısıtlar ve modelin çözüm parametreleri detaylı şekilde gösterilmiştir. Bu senaryo, mevcut durumun nasıl optimize edilebileceğine dair temel bir analiz sunmaktadır ve diğer senaryolar için bir karşılaştırma noktası oluşturmaktadır. Devam eden kısımlarda, optimizasyon sonucunda elde edilen maliyet düşüşleri ve süreç iyileştirmeleri ayrıntılı şekilde ele alınacaktır.



Şekil 6.37. 2023 Optv1 OpenSolver Görüntüsü

Şekilde 6.37'de OpenSolver'ın ayarları ve CBC çözücüsünün seçimi gösterilmektedir. "Objective Cell" kısmında toplam maliyeti temsil eden hücre seçilmiş, "Variable Cells" kısmında modelin değişkenleri belirtilmiş ve "Constraints" kısmında ise optimizasyon sürecinde dikkate alınacak kısıtlar eklenmiştir. Bu yapı, modelin esnek bir şekilde çalışmasını ve belirlenen parametreler çerçevesinde maliyetin minimize edilmesini sağlamaktadır.



Şekil 6.38. Kullanılan Çözücü Algoritması

Şekil 6.38’de gösterilen modelde, CBC (Coin-or Branch and Cut) çözücüsü tercih edilmiştir. CBC, karma tamsayılı programlama problemlerini çözmek için kullanılan açık kaynaklı, etkili bir doğrusal optimizasyon algoritmasıdır. Amaç fonksiyonu, toplam operasyon maliyetini minimize etmeye yönelik olarak yapılandırılmıştır.

Problemlerin çözümünde Branch-and-Bound ve Cutting Plane yöntemlerini birleştirerek çalışır. Branch-and-Bound yöntemiyle problem, daha küçük alt problemlere ayrılarak çözülürken, Cutting Plane yöntemi, problemin çözüm alanını daraltarak daha hızlı ve kesin sonuçlara ulaşılmasını sağlar. CBC'nin esnek yapısı, hem doğrusal ilişkilerle tanımlanmış optimizasyon problemlerini hem de tamsayılı değişkenlerin dahil olduğu karmaşık modelleri çözmesine olanak tanır. Bu özellikleriyle CBC, depo yerleşimi, rota planlama ve üretim çizelgelemesi gibi geniş bir uygulama yelpazesine sahiptir.

Tablo 6.2. Mevcut Durum ve 2023 Optimizasyon Sonucu Maliyetleri

Kapsam	2023-Mevcut	2023-OPTv1
Toplam Tonaj	173.578	173.578
BESLEME	186.645.978	62.849.043
DAĞITIM	₺159.893.781	₺176.145.947
ELLEÇLEME	₺209.224.935	₺184.602.206
KİRA&DEPOLAMA	₺176.833.529	₺140.007.686
TOPLAM MALİYET	₺732.598.222	₺563.604.883
Depo Sayısı	24	24
Açılan Depo	-	13
Kapanan Depo	-	13
Avantaj	-	₺168.993.339
TL/TON	₺4.221	₺3.247

Optimizasyon sonucunda Tablo 6.2’de gösterildiği üzere toplam operasyon maliyeti

563.604.883 TL olarak hesaplanmış ve mevcut duruma göre 168.993.339 TL tasarruf sağlanmıştır. Depo sayısı mevcut durumu yansıtan şekilde 24 depo olarak korunmuş, ancak maliyet kalemlerinde önemli iyileştirmeler elde edilmiştir.

- Besleme Maliyeti: Mevcut durumda 186.645.978 TL olan besleme maliyeti, optimizasyon sonucunda 62.849.043 TL seviyesine düşerek en büyük maliyet avantajının sağlandığı kalem olmuştur. Bu azalma, daha etkin bir besleme ağı tasarımı ile elde edilmiştir.
- Dağıtım Maliyeti: Dağıtım maliyetlerinde, mevcut durumdaki 159.893.781 TL maliyet optimizasyon sonrası 176.145.947 TL olarak hesaplanmıştır. Bu artış, daha kısa mesafelerdeki maliyetlerin azaltılmasına karşın, bazı rotaların yeniden düzenlenmesiyle ortaya çıkan farklılıkları yansıtmaktadır.
- Elleçleme Maliyeti: Mevcut durumda 209.224.935 TL olan elleçleme maliyeti, optimizasyon sonucunda 184.602.206 TL seviyesine düşmüştür. Bu azalma, depo operasyonlarının daha verimli hale getirilmesiyle mümkün olmuştur.
- Kira ve Depolama Maliyeti: Mevcut durumdaki 176.833.529 TL olan kira ve depolama maliyeti, optimizasyon sonucunda 140.007.686 TL'ye düşürülmüştür. Daha iyi yerleşim planlamasıyla ihtiyaç duyulan depo alanları optimize edilmiştir.
- TL/Ton Değeri: Mevcut durumda yaklaşık 4.200 TL/Ton olan birim maliyet, optimizasyon sonucunda 3.200 TL/Ton seviyelerine düşürülerek önemli bir maliyet avantajı sağlanmıştır.

Sonuç olarak, optimizasyon mevcut dağıtım ağı yapısını koruyarak önemli maliyet avantajları elde etmiş ve toplam operasyonel maliyeti %23 oranında düşürmeyi başarmıştır. Bu tasarruf, özellikle besleme maliyetlerindeki ciddi azalma ile mümkün olmuş ve şirketin lojistik verimliliğini artırmada kritik bir rol oynamıştır.

Tablo 6.3'te gösterildiği üzere toplamda 13 depo kapatılmış ve 13 yeni depo açılmıştır. Optimizasyon sonucunda, depo yerleşiminde önemli değişiklikler yapılmıştır. Görselde gri renkle gösterilen iller mevcut durumda depo bulunan ancak optimizasyon sonrası kapatılan depoları, yeşil renkle gösterilen iller ise optimizasyon sonucunda yeni açılan depoları temsil etmektedir.

Tablo 6.3. 2023 Optv1 Sonucu Depolar Listesi

Depolar 23'	23 OPT v1
ADANA	AFYONKARAHİSAR
ANKARA	AYDIN
ANTALYA	BALIKESİR
AYDIN	BARTIN
BALIKESİR	BATMAN
BURSA	BİLECİK
DENİZLİ	BURDUR
DIYARBAKIR	DENİZLİ
DÜZCE	ERZURUM
ERZURUM	GÜMÜŞHANE
GAZİANTEP	HATAY
HATAY	İSTANBUL
İZMİR	KIRIKKALE
KAYSERİ	KİLİS
KOCAELİ	KONYA
KONYA	MALATYA
KÜTAHYA	MANİSA
MALATYA	MERSİN
MERSİN	NEVŞEHİR
MUĞLA	OSMANİYE
SAMSUN	SAMSUN
ŞANLIURFA	ŞANLIURFA
TEKİRDAĞ	TEKİRDAĞ
TRABZON	VAN
KAPANAN	AÇILAN

Bu değişiklikler, dağıtım ağının daha verimli hale getirilmesi ve maliyetlerin minimize edilmesi amacıyla yapılmıştır. Yeni depo yerleşimleri, lojistik verimliliği artırarak toplam operasyonel maliyetin düşürülmesine önemli katkı sağlamıştır. Özellikle, kapanan ve açılan depolar arasındaki bu dönüşüm, şirketin dağıtım ağında daha stratejik ve maliyet etkin bir yapı oluşturduğunu göstermektedir. Bu sonuçlar, optimizasyonun önemli bir yapısal iyileştirme sağladığını kanıtlamaktadır.

6.3.6. 2023 Mevcut Dağıtım Modelinin Optimize Edilmesi (Senaryo-2)

Bu senaryoda, mevcut dağıtım modelinin optimize edilmesi için maksimum depo açma kısıtı 30 depoya yükseltilmiştir. Amaç, depo sayısındaki artışın toplam operasyon maliyetleri üzerindeki etkisini incelemek ve maliyet avantajlarını değerlendirmektir. Şekilde 6.39'da gösterildiği üzere, model OpenSolver eklentisi kullanılarak CBC çözücüsü ile çalıştırılmıştır. Yeni depo açma kısıtı ile birlikte, dağıtım ağı yapısında daha fazla esneklik sağlanarak, lojistik süreçlerin optimize edilmesi hedeflenmiştir.

maliyet avantajı sağlanmıştır.

- Besleme Maliyeti: Bu modelde besleme maliyeti 191.525.686 TL seviyesine yükselmiştir. Artan depo sayısı ile lojistik zincirin daha fazla kırılması ve tedarik sürecinin yeniden yapılandırılması, bu maliyetin yükselmesine neden olmuştur.
- Dağıtım Maliyeti: Dağıtım maliyetleri, daha fazla depo açılması ve bölgeler arasındaki mikro dağıtımın optimize edilmesi sayesinde 146.361.216 TL seviyesine düşmüştür.
- Elleçleme Maliyeti: Depo sayısındaki artışa paralel olarak elleçleme maliyetleri 189.541.275 TL olarak gerçekleşmiştir.
- Kira ve Depolama Maliyeti: Artan depo sayısına rağmen toplam kira ve depolama maliyetleri 153.665.101 TL ile makul bir seviyede tutulmuştur.

Optimizasyon Modellerinin Karşılaştırması:

- Mevcut Durum ile Karşılaştırma: Mevcut durumda toplam maliyet 732.598.222 TL iken, Optimizasyon-2 modeliyle bu maliyet 681.093.278 TL'ye düşürülmüştür. Bu da %7'lik bir iyileşme anlamına gelir.
- Optimizasyon-1 ile Karşılaştırma: Optimizasyon-1 modelinde toplam maliyet 563.604.883 TL seviyesindeyken, Optimizasyon-2 modelinde bu rakam yükselmiştir. Artan depo sayısı, dağıtım maliyetlerini düşürse de diğer maliyet kalemlerinde yükselmeye neden olmuştur.
- TL/Ton Maliyeti: Mevcut durumda yaklaşık 4.200 TL/Ton olan maliyet, Optimizasyon-2 ile 3.900 TL/Ton seviyesine düşürülmüştür. Ancak, Optimizasyon-1'de elde edilen 3.200 TL/Ton seviyesine ulaşılmamıştır.
- Genel Değerlendirme: Optimizasyon-2 modeli, daha fazla depo açılmasıyla dağıtım maliyetlerinde iyileşme sağlamış ancak besleme ve elleçleme maliyetlerindeki artış nedeniyle toplamda daha az bir tasarruf sağlamıştır. Optimizasyon-1, toplam maliyetleri minimize etmek açısından daha etkili bir sonuç sunarken, Optimizasyon-2 modeli, dağıtım ağının genişlemesi ve lojistik zincirin esnekliğini artırması açısından avantajlar sağlamıştır. Hangi modelin tercih edileceği, maliyet tasarrufu ile operasyonel esneklik arasında yapılacak bir dengeye bağlıdır.

Tablo 6.5. Optv1 ve Optv2 Depolar Listesi

Depolar 23'	23 OPT v1	23 OPT v2
ADANA	AFYONKARAHİSAR	AFYONKARAHİSAR
ANKARA	AYDIN	AYDIN
ANTALYA	BALIKESİR	BALIKESİR
AYDIN	BARTIN	BARTIN
BALIKESİR	BATMAN	BURDUR
BURSA	BİLECİK	BURSA
DENİZLİ	BURDUR	ÇANAKKALE
DIYARBAKIR	DENİZLİ	DENİZLİ
DÜZCE	ERZURUM	DIYARBAKIR
ERZURUM	GÜMÜŞHANE	DÜZCE
GAZİANTEP	HATAY	ERZİNCAN
HATAY	İSTANBUL	ERZURUM
İZMİR	KIRIKKALE	HATAY
KAYSERİ	KİLİS	İSTANBUL
KOCAELİ	KONYA	KIRIKKALE
KONYA	MALATYA	KIRKLARELİ
KÜTAHYA	MANİSA	KİLİS
MALATYA	MERSİN	KONYA
MERSİN	NEVŞEHİR	MALATYA
MUĞLA	OSMANİYE	MANİSA
SAMSUN	SAMSUN	MERSİN
ŞANLIURFA	ŞANLIURFA	NEVŞEHİR
TEKİRDAĞ	TEKİRDAĞ	OSMANİYE
TRABZON	VAN	SAMSUN
		SİVAS
		ŞANLIURFA
		TEKİRDAĞ
		TRABZON
		VAN
		YALOVA
	KAPANAN	AÇILAN

Tablo 6.5'te mevcut durum, Optimizasyon-1 ve Optimizasyon-2 modelleri karşılaştırılarak, açılan ve kapanan depo değişiklikleri detaylı bir şekilde gösterilmiştir.

- Mevcut Durum ile Optimizasyonlar: Optimizasyon modellerinde depo yerleşiminde ciddi bir yeniden yapılandırma gerçekleşmiş ve açılan/kapanan depolar maliyet etkinliği gözetilerek belirlenmiştir.
- OPTv1 ile OPTv2 Karşılaştırması: Optimizasyon-2'de depo sayısının artırılması, dağıtım maliyetlerini düşürse de, kira ve besleme maliyetlerini artırarak toplam maliyet avantajını azaltmıştır. Optimizasyon-1 ise daha dengeli bir maliyet düşüşü sunmuştur.

6.3.7. 2024 Yılı Tahmini Satışlarına Göre Optimizasyon

Bu bölümde, Matlab üzerinde Yapay Sinir Ağları ile tahmin edilen 2024 yılı toplam satış verileri kullanılarak, dağıtım ağı optimizasyon modeli yeniden değerlendirilmiştir. Tahmini satış verileri, gelecekteki talep artışlarını ve bölgesel dağılımı öngörerek, maliyetlerin minimize edilmesi ve lojistik süreçlerin daha etkin hale getirilmesi için modelin parametrelerine entegre edilmiştir. Optimizasyon sürecinde, 2024 yılı tahminleri doğrultusunda depo yerleşimleri ve operasyon maliyetleri yeniden yapılandırılmış ve

dağıtım ağının stratejik olarak iyileştirilmesi hedeflenmiştir. Devam eden kısımlarda, modelin uygulanışı ve elde edilen sonuçlar detaylı şekilde ele alınacaktır.

Tablo 6.6. 2023 Optv1 ve 2024 Optv2 Maliyet Karşılaştırması

Kapsam	2023-OPTv1	24 OPT v1
Toplam Tonaj	173.578	145.526
BESLEME	62.849.043	₺150.973.715
DAĞITIM	₺176.145.947	₺144.182.479
ELLEÇLEME	₺184.602.206	₺157.906.267
KİRA&DEPOLAMA	₺140.007.686	₺120.101.647
TOPLAM MALİYET	₺563.604.883	₺573.164.108
Depo Sayısı	24	24
Açılan Depo	13	1
Kapanan Depo	13	1
Avantaj	₺168.993.339	₺159.434.115
TL/TON	₺3.247	₺3.939

Tablo 6.6’da gösterildiği üzere 2024 yılı tahmini satışlarına göre yapılan optimizasyon modelinde, toplam tonajın 145 bin ton seviyelerine düşmesiyle birlikte, depo sayısı 2023 yılı ile aynı tutulmuş ve operasyonel yapı korunmuştur. Ancak, depo sayısının aynı kalması ve tonajın azalması, maliyetlerin ton başına daha yüksek bir seviyede kalmasına neden olmuştur.

Model sonuçlarına göre toplam operasyon maliyeti, 573.164.108 TL seviyesinde gerçekleşerek 2023 yılıyla benzer bir seviyede kalmıştır. Ancak, TL/Ton bazında maliyetlerde artış gözlenmiştir. Bu durum, düşük tonaj miktarına rağmen aynı depo sayısının korunmasıyla ortaya çıkan sabit giderlerin artan etkisini göstermektedir. Bu model, düşük tonajlı senaryolarda depo ağının yeniden yapılandırılması ve depo sayısının optimize edilmesi gerektiğini açıkça ortaya koymaktadır.

2025 yılının tahmini ve tonajın tekrar yukarı çıkması ihtimaline karşılık depo kapatma opsiyonu önerilmemiştir.

Tablo 6.7. 2024 Optv1 Depolar Listesi

23 OPT v1	24 OPT v1
AFYONKARAHİSAR	AFYONKARAHİSAR
AYDIN	AYDIN
BALIKESİR	BALIKESİR
BARTIN	BARTIN
BATMAN	BİLECİK
BİLECİK	BURDUR
BURDUR	DENİZLİ
DENİZLİ	DİYARBAKIR
ERZURUM	ERZURUM
GÜMÜŞHANE	GÜMÜŞHANE
HATAY	HATAY
İSTANBUL	İSTANBUL
KIRIKKALE	KIRIKKALE
KİLİS	KİLİS
KONYA	KONYA
MALATYA	MALATYA
MANİSA	MANİSA
MERSİN	MERSİN
NEVŞEHİR	NEVŞEHİR
OSMANİYE	OSMANİYE
SAMSUN	SAMSUN
ŞANLIURFA	ŞANLIURFA
TEKİRDAĞ	TEKİRDAĞ
VAN	VAN
KAPANAN	AÇILAN

2023 yılının ilk optimizasyon senaryosu (OPTv1) ile 2024 yılı tahmini satışlarına göre yapılan optimizasyon (24 OPTv1) karşılaştırıldığında, Tablo 6.7’de belirtildiği üzere toplam depo sayısı aynı kalmış olmasına rağmen, 3 depo yerleşiminde değişiklik gerçekleşmiştir.

6.3.8. Tüm Modellerin Karşılaştırılması

Tablo 6.8’de 2023 Mevcut Durum, 2023 Optimizasyon Modelleri ve 2024 Optimizasyon sonuç çıktılarının mali açıdan karşılaştırılması verilmiştir. Tablonun hemen devamında ise Mevcut Durum ve Optimizasyon sonuçlarının karşılaştırmaları detaylı olarak açıklanmıştır.

Tablo 6.8. 2023 ve 2024 Tüm Modellerin Karşılaştırması

Kapsam	2023-Mevcut	2023-OPTv1	2023-OPTv2	24 OPT v1
Toplam Tonaj	173.578	173.578	173.578	145.526
BESLEME	186.645.978	62.849.043	191.525.686	₺150.973.715
DAĞITIM	₺159.893.781	₺176.145.947	₺146.361.216	₺144.182.479
ELLEÇLEME	₺209.224.935	₺184.602.206	₺189.541.275	₺157.906.267
KİRA&DEPOLAMA	₺176.833.529	₺140.007.686	₺153.665.101	₺120.101.647
TOPLAM MALİYET	₺732.598.222	₺563.604.883	₺681.093.278	₺573.164.108
Depo Sayısı	24	24	30	24
Açılan Depo	-	13	-	1
Kapanan Depo	-	13	-	1
Avantaj	-	₺168.993.339	₺51.504.944	₺159.434.115
TL/TON	₺4.221	₺3.247	₺3.924	₺3.939


- 2023 Mevcut Durum:
 - Toplam maliyet: 732.598.222 TL
 - Depo sayısı: 24
 - En yüksek maliyet kalemi: Elleçleme maliyeti (209.224.935 TL)
 - TL/Ton maliyeti yüksek seviyede kalmıştır. Bu durum, mevcut ağırlık maliyet etkinliği açısından iyileştirilmesi gerektiğini göstermektedir.
- 2023 Optimizasyon (OPTv1):
 - Toplam maliyet: 563.604.883 TL
 - Depo sayısı: 24
 - Mevcut duruma göre toplamda 168.993.339 TL tasarruf sağlanmıştır.
 - Besleme maliyetinde ciddi bir düşüş (62.849.043 TL) sağlanmış ve TL/Ton maliyeti önemli ölçüde azaltılmıştır.
 - En dengeli ve maliyet açısından verimli senaryo olarak öne çıkmıştır.
- 2023 30 Depolu Optimizasyon (OPTv2):
 - Toplam maliyet: 681.093.278 TL
 - Depo sayısı: 30
 - Mevcut duruma göre toplamda 51.504.944 TL tasarruf sağlanmıştır.
 - Dağıtım maliyetlerinde düşüş sağlanmış (146.361.216 TL), ancak besleme ve elleçleme maliyetlerinde artış gözlemlenmiştir.

- Daha geniş bir depo ağı, operasyonel esneklik sunarken maliyet avantajlarını sınırlamıştır.
- 2024 Tahmini Satışlarına Göre Optimizasyon (24 OPTv1):
 - Toplam maliyet: 573.164.108 TL
 - Depo sayısı: 24
 - 2023 OPTv1'e kıyasla toplam maliyet bir miktar artmıştır. Bunun sebebi, 2024 yılı tahminlerinde toplam tonajın düşmesi (145.000 ton) ve sabit depo giderlerinin aynı kalmasıdır.
 - TL/Ton maliyeti yüksektir, bu da tonajın düşüşüne rağmen depo sayısının korunmasıyla ilişkilidir.
- Genel Değerlendirme:
 - En Verimli Model: 2023 OPTv1, toplam maliyeti en düşük seviyeye indirerek ve TL/Ton maliyetini optimize ederek maliyet açısından en başarılı sonuçları sağlamıştır.
 - Depo Ağı Esnekliği: 30 depo içeren OPTv2 modeli, dağıtım ağında daha fazla esneklik sunsa da, toplam maliyet avantajı sınırlı kalmıştır.
 - 2024 Tahminleri ile Optimizasyon: Tonajın düşmesi, sabit maliyetlerin etkisini artırmış ve TL/Ton maliyetinde yükselmeye yol açmıştır. Bu durum, depo sayısının dinamik bir şekilde yeniden yapılandırılması gerektiğini ortaya koymaktadır.
 - Sonuç olarak, dağıtım ağı stratejisinde maliyet ve operasyonel esneklik arasındaki dengeyi sağlamak kritik önem taşımaktadır. 2023 OPTv1, bu dengeyi en verimli şekilde sunarken, diğer senaryolar farklı operasyonel ihtiyaçlara yanıt verebilecek şekilde yapılandırılmıştır.

6.3.9. 2024 Yılı Tahmini Satışlarına Göre Optimizasyon Senaryo-2

Bu senaryoda, 2024 yılı tahmini satış verileri temel alınarak alternatif bir çözüm sunulmuştur. Daha farklı bir çözüm olabilmesi için Maksimum depo açma sayısı 30'a çıkarılmıştır. Amaç, artan depo sayısının toplam maliyetler üzerindeki etkisini analiz etmek ve dağıtım ağını daha esnek bir yapıya kavuşturmadır. Şekil 6.40'da gösterildiği üzere Model, OpenSolver kullanılarak optimize edilmiş ve lojistik süreçlerin verimliliğini artırmak için depo yerleşimleri yeniden yapılandırılmıştır. Devam eden kısımlarda, bu

senaryonun sonuçları ve mevcut duruma göre sağladığı avantajlar detaylı olarak ele alınacaktır.



Şekil 6.40. 2024 Senaryo-2 Optimizasyon Modeli

2024 yılı tahmini satışlarına göre yapılan optimizasyonun ikinci senaryosunda, maksimum depo açma sayısı 30 olarak belirlenmiş ve önceki modele göre depo yerleşiminde önemli değişiklikler gerçekleştirilmiştir. Tablo 6.9’da gösterildiği üzere 24 OPTv1 modeliyle karşılaştırıldığında, toplam maliyetin 9.351.077 TL daha düşük olduğu görülmektedir. Bu fark, özellikle dağıtım maliyetlerinde sağlanan düşüşten (144.182.479 TL’den 126.261.720 TL’ye) kaynaklanmıştır. Ancak, elleçleme maliyetleri ve kira & depolama maliyetleri bir miktar artış göstermiştir.

Tablo 6.9. 2024 Optv1 ve 2024 Optv2 Karşılaştırması

Kapsam	24 OPT v1	24 OPT v2
Toplam Tonaj	145.526	145.526
BESLEME	₺150.973.715	151.528.200
DAĞITIM	₺144.182.479	126.261.720
ELLEÇLEME	₺157.906.267	159.635.579
KİRA&DEPOLAMA	₺120.101.647	126.387.532
TOPLAM MALİYET	₺573.164.108	₺563.813.031
Depo Sayısı	24	30
Açılan Depo	1	7
Kapanan Depo	1	1
Avantaj		₺9.351.077
TL/TON	₺3.939	₺3.874

Açılan ve kapanan depo sayıları incelendiğinde, 24 OPTv2 modelinde sadece 1 depo

açılmış ve 3 depo kapatılmıştır. Bu, dağıtım ağının daha stratejik bir şekilde yeniden yapılandırıldığını göstermektedir. TL/Ton maliyetleri de optimize edilerek daha düşük seviyelere çekilmiştir, ancak sabit maliyetlerin etkisi göz önünde bulundurulduğunda, büyük tonaj düşüşüyle beraber maliyet avantajı sınırlı kalmıştır.

Sonuç olarak, 24 OPTv2 modeli, daha geniş bir depo ağı oluşturulmasına rağmen toplam maliyetlerin düşürülmesini sağlamış ve lojistik süreçlerin esnekliğini artırmıştır. Ancak, maliyet avantajı ilk optimizasyon modeli (24 OPTv1) ile kıyaslandığında daha sınırlıdır, bu da tonajın düşük olduğu senaryolarda depo sayısının dikkatle yönetilmesi gerektiğini göstermektedir.

Tablo 6.10'da 24 OPTv1 ve 24 OPTv2 modelleri depo karşılaştırması yapılmıştır. 24 OPTv2 modelinde 1 depo kapatılmış ve 7 yeni depo açılmıştır. Kapatılan depo Bilecik, açılan yeni depolar ise Bursa, Çanakkale, Düzce, Kırklareli, Kütahya, Sivas ve Yalova illerinde konumlanmıştır. Bu değişiklikler, dağıtım ağını daha stratejik ve verimli bir yapıya dönüştürmek için gerçekleştirilmiş olup, toplam operasyonel maliyetlerin azaltılmasına ve lojistik süreçlerin iyileştirilmesine katkı sağlamıştır. Yeni depoların açılması, özellikle belirli bölgelerdeki dağıtım maliyetlerinin optimize edilmesine yöneliktir.


Tablo 6.10 2024 Optv1 ve Optv2 Depolar Listesi

24 OPT v1	24 OPT v2
AFYONKARAHİSAR	AFYONKARAHİSAR
AYDIN	AYDIN
BALIKESİR	BALIKESİR
BARTIN	BARTIN
BİLECİK	BURDUR
BURDUR	BURSA
DENİZLİ	ÇANAKKALE
DIYARBAKIR	DENİZLİ
ERZURUM	DIYARBAKIR
GÜMÜŞHANE	DÜZCE
HATAY	ERZURUM
İSTANBUL	GÜMÜŞHANE
KIRIKKALE	HATAY
KİLİS	İSTANBUL
KONYA	KIRIKKALE
MALATYA	KIRKLARELİ
MANİSA	KİLİS
MERSİN	KONYA
NEVŞEHİR	KÜTAHYA
OSMANİYE	MALATYA
SAMSUN	MANİSA
ŞANLIURFA	MERSİN
TEKİRDAĞ	NEVŞEHİR
VAN	OSMANİYE
	SAMSUN
	SIVAS
	ŞANLIURFA
	TEKİRDAĞ
	VAN
	YALOVA

6.3.10. 2025 Yılı Tahmini Satışlarına Göre Optimizasyon Senaryo-1

Bu bölümde, 2025 yılı için tahmin edilen yıllık toplam satış miktarı olan 167.490 ton temel alınarak, dağıtım ağı optimizasyonu gerçekleştirilecektir. Amaç, bu tahmini satış verilerine dayalı olarak, toplam operasyonel maliyetleri minimize ederken en uygun depo yerleşimlerini ve lojistik süreçleri belirlemektir. Optimizasyon modelleri, 2025 yılı satış tahminleri doğrultusunda depo sayıları, maliyet bileşenleri ve dağıtım ağı parametreleri yeniden değerlendirilerek çalıştırılacaktır.

Hedef, artan yıllık tonajın etkilerini göz önünde bulundurarak, lojistik verimliliği artıracak ve maliyet avantajı sağlayacak stratejik bir dağıtım ağı yapısı oluşturmaktır. Devam eden kısımlarda, yapılan optimizasyon çalışmaları ve elde edilen sonuçlar detaylı bir şekilde ele alınacaktır. Şekilde 6.41’de ise 2025 Senaryo-1 Optimizasyon modeline giriş kısmı gösterilmiştir.



Şekil 6.41. 2025 Senaryo-1 Optimizasyon Modeli

Tablo 6.11’de 2025 Optimizasyon v1 Modelinin sonuçları gösterilmiştir.

Tablo 6.11. 2025 Optv1 Maliyet Analizi Tablosu

Kapsam	25 OPT v1
Toplam Tonaj	167.490
BESLEME	171.761.857
DAĞITIM	161.176.751
ELLEÇLEME	183.343.606
KİRA&DEPOLAMA	142.622.259
TOPLAM MALİYET	₺658.904.474
Depo Sayısı	24
Açılan Depo	-
Kapanan Depo	-
Avantaj	
TL/TON	₺3.934

2025 yılı tahmini toplam satış miktarı olan 167.490 ton baz alınarak gerçekleştirilen optimizasyon modeli, toplam operasyon maliyetini 658.904.474 TL olarak gerçekleştirmiştir. Model, artan tonajın lojistik süreçlere etkisini dikkate alarak, maliyet bileşenlerini optimize etmeyi hedeflemiştir.


Sonuç olarak, 25 OPTv1 modeli, artan tonaj doğrultusunda maliyet bileşenlerini optimize ederek toplam operasyon maliyetlerini düşük seviyelerde tutmayı başarmıştır. Ancak, dağıtım ve elleçleme maliyetlerindeki artış, tonajın artışıyla doğru orantılıdır. Bu durum, 2025 yılı için daha stratejik depo yerleşimlerinin ve maliyet düşürücü önlemlerin dikkate alınması gerektiğini göstermektedir. Devam eden senaryolarda, depo sayısının artırılması veya farklı yapılandırmaların etkileri değerlendirilecektir.

6.3.11. 2025 Yılı Tahmini Satışlarına Göre Optimizasyon Senaryo-2

Bu senaryoda, 2025 yılı tahmini satış verileri temel alınarak maksimum depo açma sayısı 30 olarak belirlenmiştir. Amaç, artan depo sayısı ile lojistik süreçlerde daha fazla esneklik sağlamak ve toplam operasyon maliyetlerini minimize etmektir. Optimizasyon modeli, artan depo sayısının maliyet bileşenlerine etkisini değerlendirmek ve en verimli dağıtım ağı yapısını oluşturmak için yapılandırılmıştır.

Devam eden kısımlarda, bu senaryonun sonuçları mevcut durum ve diğer optimizasyon senaryolarıyla karşılaştırılarak analiz edilecek ve depo yerleşimleri ile maliyet avantajları

detaylı şekilde incelenecektir. Şekil 6.42’de ise Optimizasyon Modelinin Excel kurgusu gösterilmiştir.



Şekil 6.42. 2025 Senaryo-2 Optimizasyon Modeli

Tablo 6.12’de 2025 Optimizasyon v1 ve Optimizasyon v2 model sonuç karşılaştırmalarına yer verilmiştir.

Tablo 6.12. 2025 Optv1 ve 2025 Optv2 Karşılaştırması

Kapsam	25 OPT v1	25 OPT v2
Toplam Tonaj	167.490	167.490
BESLEME	171.761.857	172.278.249
DAĞITIM	161.176.751	137.351.489
ELLEÇLEME	183.343.606	187.651.371
KİRA&DEPOLAMA	142.622.259	151.376.882
TOPLAM MALİYET	£658.904.474	£648.657.992
Depo Sayısı	24	30
Açılan Depo	-	8
Kapanan Depo	-	2
Avantaj		£10.246.482
TL/TON	£3.934	£3.873

2025 yılı tahmini satış verilerine göre gerçekleştirilen her iki optimizasyon modeli karşılaştırıldığında, 25 OPTv2 modelinin toplam maliyet açısından daha avantajlı olduğu görülmektedir. 25 OPTv2, toplam operasyon maliyetini 648.657.992 TL seviyesine indirerek, 25 OPTv1 modeline kıyasla 10.246.482 TL tasarruf sağlamıştır. Bu fark, özellikle dağıtım maliyetlerindeki iyileştirmelerle elde edilmiştir.

25 OPTv2 modeli, depo sayısının artırılmasıyla lojistik ağda daha geniş bir esneklik sunmuş, maliyetleri optimize ederek operasyonel verimliliği artırmıştır. Bu senaryo, artan

tonaj karşısında stratejik depo yerleşimlerinin etkisini açıkça göstermektedir. Ancak, artan depo sayısının elleçleme ve kira maliyetlerinde sınırlı bir artışa neden olduğu da dikkate alınmalıdır. Genel olarak, 25 OPTv2, maliyet optimizasyonu ve lojistik verimlilik açısından 2025 hedeflerine daha uygun bir çözüm sunmaktadır.

Tablo 6.13'te 2025 OPTv1 ve 2025 OPTv2 modeli sonuçlarına göre açılan ve kapanan depolar listelenmiştir. 25 OPTv2 modelinde, dağıtım ağına yapılan değişikliklerle birlikte 2 depo kapatılmış ve 8 yeni depo açılmıştır. Kapatılan depolar Bilecik ve Gümüşhane illerinde yer alırken, yeni açılan depolar Bursa, Çanakkale, Düzce, Erzinan, Kırklareli, Osmaniye, Sivas ve Yalova illerinde konumlanmıştır.

Bu değişiklikler, artan tonajı daha verimli bir şekilde karşılamak ve maliyet avantajı sağlamak amacıyla gerçekleştirilmiştir. Yeni açılan depolar, lojistik ağına stratejik noktalarına yerleştirilerek dağıtım ve besleme süreçlerinin optimize edilmesine olanak tanımıştır. Bu sonuçlar, depo yerleşimindeki esnekliğin operasyonel maliyetler üzerindeki olumlu etkisini bir kez daha göstermektedir.

Tablo 6.13. 2025 Optv1 ve 2025 Optv2 Depolar Listesi

25 OPT v1	25 OPT v2
AFYONKARAHİSAR	AFYONKARAHİSAR
AYDIN	AYDIN
BALIKESİR	BALIKESİR
BARTIN	BARTIN
BİLECİK	BURDUR
BURDUR	BURSA
DENİZLİ	ÇANAKKALE
DIYARBAKIR	DENİZLİ
ERZURUM	DIYARBAKIR
GÜMÜŞHANE	DÜZCE
HATAY	ERZİNCAN
İSTANBUL	ERZURUM
KIRIKKALE	HATAY
KİLİS	İSTANBUL
KONYA	KIRIKKALE
MALATYA	KIRKLARELİ
MANİSA	KİLİS
MERSİN	KONYA
NEVŞEHİR	MALATYA
OSMANİYE	MANİSA
SAMSUN	MERSİN
ŞANLIURFA	NEVŞEHİR
TEKİRDAĞ	OSMANİYE
VAN	SAMSUN
	SİVAS
	ŞANLIURFA
	TEKİRDAĞ
	TRABZON
	VAN
	YALOVA

6.3.12. Tüm Modellerin Karşılaştırması

Tablo 6.14'te 2023 Mevcut Durum, 2023 Optv1, 2024 Optv1 ve 2025 Optv1 sonuçları ve alt kırılımları karşılaştırılmıştır. Karşılaştırma detayları ise tablonun devamında açıklanmıştır.

Genel Bakış ve Tonaj Değişimleri:

2023 mevcut durumda toplam tonaj 173.578 ton olarak belirlenmiş, bu tonaj 2024 yılında 145.526 ton seviyesine düşerken 2025 yılı için tekrar artış göstererek 167.490 ton seviyesine yükselmiştir. Bu tonaj değişiklikleri, maliyet bileşenleri üzerinde doğrudan bir etkiye sahiptir. Azalan tonaj, birim maliyetleri artırırken (TL/Ton), artan tonaj maliyetlerin daha verimli dağılmasını sağlamıştır.

Tablo 6.14. 2023 Mevcut 2024-2025 Optimizasyon Sonuçlarının Mali Karşılaştırması

	2023		2024	2025
Kapsam	2023-Mevcut	2023-OPTv1	24 OPT v1	25 OPT v1
Toplam Tonaj	173.578	173.578	145.526	167.490
BESLEME	186.645.978	62.849.043	₺150.973.715	171.761.857
DAĞITIM	₺159.893.781	₺176.145.947	₺144.182.479	161.176.751
ELLEÇLEME	₺209.224.935	₺184.602.206	₺157.906.267	183.343.606
KİRA&DEPOLAMA	₺176.833.529	₺140.007.686	₺120.101.647	142.622.259
TOPLAM MALİYET	₺732.598.222	₺563.604.883	₺573.164.108	₺658.904.474
Depo Sayısı	24	24	24	24
Açılan Depo	-	13	1	-
Kapanan Depo	-	13	1	-
Avantaj	-	₺168.993.339	₺159.434.115	₺73.693.749
TL/TON	₺4.221	₺3.247	₺3.939	₺3.934

Depo Sayısının Sabit Tutulması:

Her dört senaryoda da depo sayısı 24 olarak sabit tutulmuş, bu da kira ve depolama maliyetlerini kontrol altında tutmaya katkı sağlamıştır. Ancak sabit depo sayısı, düşük tonajlı yıllarda (2024 gibi) birim maliyetlerin yükselmesine neden olmuştur. 2024'te TL/Ton maliyeti 3.939 TL, 2025'te ise tonajın artmasıyla hafif bir iyileşme göstererek 3.934 TL seviyesine düşmüştür.

Besleme Maliyeti:

- 2023 Mevcut Durum: 159.893.781 TL
- 2023 OPTv1: Optimizasyon sonucunda besleme maliyeti 62.849.043 TL seviyesine düşerek ciddi bir tasarruf sağlanmıştır. Bu, optimizasyonun en büyük maliyet avantajının bu kalemde elde edildiğini göstermektedir.
- 2024 ve 2025: Besleme maliyeti 2024'te 150.973.715 TL, 2025'te ise artan tonajın etkisiyle 120.781.265 TL olarak gerçekleşmiştir. Tonaj artışı, maliyetin verimli şekilde dağılmasına yardımcı olmuştur.

Dağıtım Maliyeti:

- 2023 Mevcut Durum: 159.893.781 TL
- 2023 OPTv1: Dağıtım maliyeti optimize edilerek 176.145.947 TL'ye çıkarılmıştır. Bu artış, optimizasyonun dağıtım ağı üzerinde oluşturduğu yeniden yapılanmanın bir sonucudur.
- 2024 ve 2025: Dağıtım maliyetleri sırasıyla 144.182.479 TL ve 180.155.712 TL olarak gerçekleşmiştir. 2025'teki artış, daha yüksek tonajın getirdiği geniş dağıtım ihtiyacını yansıtmaktadır.

Elleçleme Maliyeti:

- 2023 Mevcut Durum: 209.224.935 TL
- 2023 OPTv1: Elleçleme maliyeti 184.602.206 TL seviyesine düşürülmüştür.
- 2024 ve 2025: Elleçleme maliyetleri 2024'te 157.906.267 TL, 2025'te 187.390.583 TL olarak gerçekleşmiştir. Tonaj artış ve azalışları bu kalemdeki değişimi doğrudan etkilemiştir.

Kira ve Depolama Maliyeti:

Bu maliyet, sabit depo sayısı nedeniyle oldukça kontrollü bir yapıda kalmıştır:

- 2023 Mevcut Durum: 176.833.529 TL
- 2023 OPTv1: Optimizasyon sonrası 140.007.686 TL seviyesine düşürülmüştür.

- 2024 ve 2025: Bu maliyet 2024'te 120.101.647 TL, 2025'te ise 120.594.451 TL olarak benzer seviyelerde kalmıştır.

TL/Ton Değeri:

- 2023 Mevcut Durum: 4.221 TL/Ton ile en yüksek seviyededir.
- 2023 OPTv1: 3.247 TL/Ton ile en düşük seviyeye inmiştir.
- 2024 ve 2025: TL/Ton değerleri sırasıyla 3.939 TL ve 3.934 TL olarak kaydedilmiştir. Bu, tonajın etkisini açıkça göstermektedir; düşük tonaj maliyetleri yükseltirken, artan tonaj maliyetleri daha verimli bir şekilde dağıtmaktadır. Optimizasyon çalışmaları, sabit depo sayısı ile toplam maliyetlerde önemli düşüşler sağlamıştır. 2023 OPTv1 modeli, en düşük TL/Ton değerine ulaşarak maliyet açısından en verimli sonuçları vermiştir. 2024 yılında düşen tonaj nedeniyle TL/Ton maliyeti yükselmiş, ancak 2025 yılında artan tonaj sayesinde bu değer tekrar iyileşmiştir. Depo sayısının sabit tutulduğu bu yapı, maliyetlerin kontrollü bir şekilde optimize edilmesine olanak sağlamış, ancak düşük tonajlı yıllarda sabit giderlerin etkisiyle birim maliyetlerde artışlara neden olmuştur. Bu analiz, tonaj değişimlerinin maliyetler üzerindeki doğrudan etkisini ve lojistik optimizasyonun önemini açıkça ortaya koymaktadır.

Tablo 6.15'te Mevcut Durum ve 2023, 2024, 2025 Optimizasyon Sonuçlarına göre Bölge Depoların hangi illerde ve kaç yıl boyunca açık kalacağı bilgileri gösterilmiştir. Tablonun devamında ise detaylı açıklamalar yapılmıştır.

Her modelde depo yerleşimlerinde yapılan değişiklikler, lojistik süreçlerin optimizasyonu ve maliyetlerin düşürülmesi amacıyla planlanmıştır. Depoların açık kalma süreleri, stratejik önemlerini ve operasyonel verimliliklerini yansıtmaktadır.

- Kapatılan Depolar (Gri): Adana, Ankara, Antalya, Denizli, Diyarbakır, Düzce, Gaziantep, İzmir, Kayseri, Kocaeli, Kütahya, Muğla ve Trabzon gibi depolar, mevcut lojistik ihtiyaçlara uygun olmadıkları veya maliyet etkinliği sağlamadıkları için kapatılmıştır. Bu değişiklik, kaynakların daha verimli kullanılmasını hedeflemiştir.

Tablo 6.15. 2023 Mevcut Durum, 2024 ve 2025 Optimum Depo Yerleşimine Göre

Depoların Çalışma Süreleri

Depolar 23'	23 OPT v1	24 OPT v1	25 OPT v1
ADANA	AFYONKARAHİSAR	AFYONKARAHİSAR	AFYONKARAHİSAR
ANKARA	AYDIN	AYDIN	AYDIN
ANTALYA	BALIKESİR	BALIKESİR	BALIKESİR
AYDIN	BARTIN	BARTIN	BARTIN
BALIKESİR	BATMAN	BİLECİK	BİLECİK
BURSA	BİLECİK	BURDUR	BURDUR
DENİZLİ	BURDUR	DENİZLİ	DENİZLİ
DİYARBAKIR	DENİZLİ	DİYARBAKIR	DİYARBAKIR
DÜZCE	ERZURUM	ERZURUM	ERZURUM
ERZURUM	GÜMÜŞHANE	GÜMÜŞHANE	GÜMÜŞHANE
GAZİANTEP	HATAY	HATAY	HATAY
HATAY	İSTANBUL	İSTANBUL	İSTANBUL
İZMİR	KIRIKKALE	KIRIKKALE	KIRIKKALE
KAYSERİ	KİLİS	KİLİS	KİLİS
KOCAELİ	KONYA	KONYA	KONYA
KONYA	MALATYA	MALATYA	MALATYA
KÜTAHYA	MANİSA	MANİSA	MANİSA
MALATYA	MERSİN	MERSİN	MERSİN
MERSİN	NEVŞEHİR	NEVŞEHİR	NEVŞEHİR
MUĞLA	OSMANİYE	OSMANİYE	OSMANİYE
SAMSUN	SAMSUN	SAMSUN	SAMSUN
ŞANLIURFA	ŞANLIURFA	ŞANLIURFA	ŞANLIURFA
TEKİRDAĞ	TEKİRDAĞ	TEKİRDAĞ	TEKİRDAĞ
TRABZON	VAN	VAN	VAN
KAPATILAN	1 YIL AÇIK KALAN	2 YIL AÇIK KALAN	3 YIL AÇIK KALAN

- 1 Yıl Açık Kalan Depolar (Beyaz): Örneğin, Batman gibi depolar, kısa vadeli lojistik ihtiyaçlara hizmet etmiş ancak uzun vadeli optimizasyon hedefleri doğrultusunda kapatılmıştır. Bu, değişen talep ve tonaj yapısına adaptasyonun göstergesidir.
- 2 Yıl Açık Kalan Depolar (Açık Mavi): Diyarbakır gibi depolar, orta vadeli lojistik planlamalarda önemli roller üstlenmiş ancak daha stratejik lokasyonların devreye girmesiyle kapanmıştır.
- 3 Yıl Açık Kalan Depolar (Koyu Mavi): Afyonkarahisar, Aydın, Balıkesir, Erzurum, İstanbul, Konya, Samsun ve Tekirdağ gibi depolar, üç farklı modelde de yer alarak, lojistik ağın en dayanıklı ve stratejik noktaları olarak öne çıkmıştır. Bu depolar, sürekli açık kalmaları nedeniyle kilit lojistik merkezler olarak değerlendirilebilir.

Şekil 6.43'te 2023 Mevcut Durum Dağıtım Ağı Haritası gösterilmiştir. Devamında gelen Şekil 6.44, Şekil 6.45 ve Şekil 6.46'da ise 2023, 2023 ve 2025 yılları için Senaryo-1 durumlarına göre Optimizasyon sonucunda oluşan dağıtım haritaları gösterilmiştir;




Şekil 6.43. 2023 Mevcut Durum Dağıtım Ağı Haritası



Şekil 6.44. 2023 Optimizasyon V1 Dağıtım Ağı Haritası



Şekil 6.45. 2024 Optimizasyon V1 Dağıtım Ağı Haritası



Şekil 6.46. 2025 Optimizasyon V1 Dağıtım Ağı Haritası

Şekiller (6.43, 6.44, 6.45 ve 6.46) incelendiğinde özellikle 2023 yılında yapılan Optimizasyon sonucunda köklü değişikliklerin olduğu görülmektedir. Takip eden 2024 ve 2025 yılları için ise yalnızca minör değişikliklerin önerildiği gözlemlenmiştir. Bu durum, ilk optimizasyon aşamasında satış tonajlarına göre en uygun dağıtım ağıının belirlenmesi amacıyla kapsamlı müdahalelerde bulunulduğunu, sonraki dönemlerde ise daha az kapsamlı düzenlemelere ihtiyaç duyulduğunu göstermektedir. Ayrıca, 2024 ve

2025 yıllarında majör deęişikliklerin olmaması, modelin daha güvenilir ve uygulanabilir olduęuna işaret etmektedir.

Genel Deęerlendirme:

Depoların açık kalma süreleri, her modelde deęişen tonaj ve lojistik ihtiyaçlara adaptasyonun önemli bir göstergesidir. Kapatılan depolar operasyonel maliyetleri düşürürken, uzun süre açık kalan depolar lojistik süreçlerin devamlılığı açısından kritik öneme sahiptir. Bu yapı, optimizasyon sürecinin dinamik ve talebe duyarlı olduğunu göstermektedir.



7. SONUÇ VE ÖNERİLER

Bu çalışmada, 2023 yılı mevcut durumundan başlayarak, 2024 ve 2025 yıllarına ait tahmini satış verileri kullanılarak lojistik süreçlerin ve dağıtım ağının optimizasyonu gerçekleştirilmiştir. Optimizasyon sürecinde temel amaç, toplam operasyon maliyetlerini minimize ederken, lojistik ağın verimliliğini artırmak ve gelecekteki taleplere uygun esnek bir yapı oluşturmaktır.

2023 yılı mevcut durumu incelendiğinde, toplam operasyon maliyetlerinin 732.598.222 TL olduğu ve depo sayısının 24 ile sınırlı kaldığı görülmüştür. Bu yapı, TL/Ton bazında yüksek bir maliyet (4.221 TL) ile dikkat çekmiştir. İlk optimizasyon modelinde, toplam operasyon maliyetleri 563.604.883 TL seviyesine düşürülmüş, TL/Ton maliyeti ise 3.247 TL'ye çekilmiştir. Bu iyileşme, özellikle besleme maliyetlerindeki %66'ya varan azalma ile mümkün olmuştur. Bu model, maliyet etkinliği açısından en başarılı sonuçları sunmuştur.

2024 yılı tahmini satış verilerine göre yapılan optimizasyonlarda, tonajın 145.526 ton seviyesine düşmesi nedeniyle birim maliyetlerin artış gösterdiği gözlenmiştir. İlk modelde toplam maliyet 573.164.108 TL olarak gerçekleşmiş, TL/Ton maliyeti ise 3.939 TL olmuştur. Ancak, bu azalan tonaj ile sabit depo giderlerinin etkisinin arttığı bir senaryo ortaya çıkmıştır. Maksimum depo sayısının artırıldığı ikinci senaryoda, maliyet avantajı sağlanarak toplam operasyon maliyeti 563.813.031 TL seviyesine düşürülmüştür. Bu senaryoda açılan yeni depolar, lojistik ağın esnekliğini artırmıştır.

2025 yılı tahmini satış verilerine göre yapılan optimizasyonlarda ise tonaj artışıyla (167.490 ton) operasyon maliyetlerinin daha verimli bir şekilde dağıtıldığı görülmüştür. İlk modelde toplam maliyet 608.922.011 TL, ikinci modelde ise 598.675.529 TL olarak hesaplanmıştır. İkinci modelde toplam maliyetlerin yaklaşık 10 milyon TL daha düşük olması, depo sayısının artırılmasıyla mümkün olmuştur. Bu durum, artan tonaj karşısında depo yerleşimlerinin stratejik olarak yeniden yapılandırılmasının maliyet etkinliğine olan katkısını göstermektedir.

Depo Yerleşimlerinin Değişimi ve Stratejik Analiz: Çalışma boyunca, depo yerleşimlerinde önemli değişiklikler yapılmıştır. Bazı depolar stratejik önemlerini

yitirerek kapatılmış, bazıları ise lojistik ağı desteklemek amacıyla yeniden açılmıştır. Örneğin, 2023'te Batman ve Sakarya gibi depolar yalnızca kısa süreli hizmet verirken, Balıkesir, Konya ve İstanbul gibi kilit noktalar her modelde yer alarak lojistik ağın merkezini oluşturmuştur. Depo sayısının artırıldığı modellerde, bölgesel taleplere yanıt verebilecek yeni noktaların açıldığı gözlenmiştir.

Genel Değerlendirme ve Öneriler: Optimizasyon modelleri, sabit depo sayısı ile yapılan senaryolarda da maliyetlerin ciddi oranda düşürülebileceğini, ancak artan tonajın getirdiği yükü depo sayısının artırılmasının operasyonel esneklik ve maliyet avantajı sağladığını göstermiştir. TL/Ton maliyetlerinde elde edilen düşüşler, dağıtım, besleme ve elleçleme maliyetlerinde yapılan iyileştirmelerle mümkün olmuştur. Bununla birlikte, tonajın azaldığı senaryolarda sabit giderlerin etkisi belirginleşmiş ve birim maliyetlerde artışa yol açmıştır.

Gelecekte, tahmini tonaj ve lojistik ihtiyaçların değişimine daha duyarlı dinamik optimizasyon modellerinin kullanılması önerilmektedir. Özellikle, esnek depo yapılarının (kısa dönemli kiralık depolar gibi) devreye alınması ve bölgesel taleplere göre dinamik lojistik çözümler geliştirilmesi, maliyetlerin daha da düşürülmesini sağlayabilir. Ayrıca, teknoloji destekli (örneğin yapay zeka ve veri analitiği) karar destek sistemlerinin entegrasyonu, lojistik süreçlerdeki verimliliği artıracaktır.

Bu çalışma, lojistik ve dağıtım ağı yönetiminde optimizasyonun önemini ve maliyet etkinliğini artırmada sağlayabileceği katkıları ortaya koymuş, aynı zamanda sektörel uygulamalar için rehber bir yaklaşım sunmuştur.

KAYNAKLAR

- Abdulvahitoğlu, A. (2021). AHP-Topsis Tabanlı Matematiksel Programlama ile Jandarma Karakolu Kuruluş Yeri Seçimi ve CAS/CBS İle Analizi. Doktora Tezi, Çukurova Üniversitesi, Fen Bilimleri Enstitüsü, Adana.
- Acar, M. (2019). Mühimmat Depo Yeri Seçimi ve Dağıtım Ağı Tasarımı Problemi: Karışık Tam Sayılı Lineer Programlama ve Uygulaması. Yüksek Lisans Tezi, Balıkesir Üniversitesi, Fen Bilimleri Enstitüsü, Balıkesir.
- Adıgüzel, B. (2022). Birleşik Yapay Sinir Ağları İle Dinamik Sanal İmalat Hücresi Oluşturma Problemi ve Bir Uygulama. Yüksek Lisans Tezi, Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Ankara.
- Akomolafe, D. (2016). Comparative Study of Biological and Artificial Neural Networks. *European Journal of Applied Engineering and Scientific Research*, 2(1), 36-46
- Ayöperken, E., Ermiş, M. (2011). İnsansız Hava Araçları İçin Üs Konumlarının Kapsama Alanı Problemi Olarak Modellenmesi ve Eniyilenmesi. *Havacılık ve Uzay Teknolojileri Dergisi*, 5(1), 61-71.
- Beale, M. H., Hagan, M. T., Demuth, H. B. (2018). *Deep Learning Toolbox User's Guide*. Maryland, USA: The Mathworks Inc.
- Bebis, G., Georgiopoulos, M. (1994). Feed-forward Neural Networks. *IEEE Potentials*, 13(4), 27-31.
- Bhattacharya, S. (1997). A Comparative Study of Different Methods of Predicting Time Series. Yüksek Lisans Tezi, Concordia University, Canada.
- Brunaud, B., Bassett, M. H., Agarwal, A., Wassick, J. M., Grossmann, I. E. (2018). Efficient Formulations for Dynamic Warehouse Location Under Discrete Transportation Costs. *Computers & Chemical Engineering*, 111, 311-323.
- Chen, C. F., Chang, Y. H., Chang, Y. W. (2009). Seasonal ARIMA Forecasting of Inbound Air Travel Arrivals to Taiwan. *Transportmetrica*, 5(2), 125-140.
- Constantino, H. A., Fernandes, P. O., Teixeira, J. P. (2016). Tourism Demand Modelling and Forecasting With Artificial Neural Network Models: The Mozambique Case Study. *Téchne – Review of Applied Management Studies*, 14(2), 113-124.
- Çoban, F. (2019). Belirsiz Koşullar Altında Talep Tahmini ve Gıda İşletmesinde Bir Uygulama. Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.
- Çuhadar, M., Kayacan, C. (2005). Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerinde Bir Deneme. *Anatolia: Turizm Araştırmaları Dergisi*, 16(1), 24-30.

- Durak, İ., Yıldız, S. M. (2015). P-Medyan Tesis Yeri Seçimi Problemi: Bir Uygulama. *Uluslararası Alanya İşletme Fakültesi Dergisi*, 7(2), 43-64.
- Efe, M., Kaynak, O. (2006). Adaptive Control and Learning Algorithms in Neural Networks. *Artificial Intelligence Journal*, 33(4), 455-478.
- Efendigil, T., Eminler, Ö. E. (2017). Havacılık Sektöründe Talep Tahminin Önemi: Yolcu Talebi Üzerine Bir Tahmin Modeli. *Yaşar Üniversitesi E-Dergisi*, 12(Ekim), 14-30.
- Elman, J. L. (1990). Finding Structure in Time. *Cognitive Science*, 14(2), 179-211.
- Elmas, Ç. (2003). *Yapay Sinir Ağları: Kuram, Mimari, Uygulama* (1. Baskı). Ankara: Seçkin.
- Guo, H., Pan, W., Liu, X. (2018). Combining a Continuous Location Model and Heuristic Techniques to Determine Oilfield Warehouse Locations Under Future Oil Well Location Uncertainty. *Soft Computing*, 22, 823-837.
- Gürsakal, N., Aydın, S. (2023). Reinforcement Learning Algoritmalarının İncelenmesi ve Örnek Uygulama Alanları. *Niğde Ömer Halisdemir Üniversitesi Mühendislik Bilimleri Dergisi*, 12(3), 421-434.
- Hopfield, J. J. (1982). Neural Networks and Physical Systems with Emergent Collective Computational Abilities. *Proceedings of the National Academy of Sciences*, 79(8), 2554-2558.
- Huber, J., Stuckenschmidt, H. (2020). Daily Retail Demand Forecasting Using Machine Learning with Emphasis on Calendric Special Days. *International Journal of Forecasting*, 36(4), 1420-1438.
- ISarle, W. S. (2002). Neural Networks FAQs. (Dal Newsgroup Usenet Comp.ai. Neuralnet)
<https://www.lps.ufrj.br/~caloba/Disciplinas%20antigas/CPE%20721%202011-2/Sarle1997%20FAQs.pdf> (Ziyaret tarihi: 25 Eylül 2024).
- Jordan, M. I. (1986). Attractor Dynamics and Parallelism in a Connectionist Sequential Machine. *Proceedings of the Eighth Annual Conference of the Cognitive Science Society*, Massachusetts, 15-17 Ağustos 1986.
- Karabacak, T., Uzundumlu, A. (2020). Kayısı Üretiminde Önde Gelen İllerin 2019-2025 Üretim Tahminleri. *IBAD Sosyal Bilimler Dergisi*, 1(1), 561-573.
- Karahan, A. (2016). İstatiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması. Doktora Tezi, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Konya.

- Karahan, M. (2015). Turizm Talebinin Yapay Sinir Ağları Yöntemiyle Tahmin Edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 20(2), 195-209.
- Kasabov, N. (1996). *Foundations of Neural Networks, Fuzzy Systems and Knowledge Engineering* (1th ed). Massachusetts: MIT Press.
- Kılıç, A. (2015). Yapay Sinir Ağları ile Yemekhane Günlük Talep Tahmini. Yüksek Lisans Tezi, Pamukkale Üniversitesi, Fen Bilimleri Enstitüsü, Denizli.
- Krajewski, L. J. (2013). *Operations Management Processes and Supply Chains* (11th ed.). Boston: Pearson.
- Krizhevsky, A., Sutskever, I., Hinton, G. E. (2012). ImageNet Classification with Deep Convolutional Neural Networks. *Communications of the ACM*, 60(6), 84-90.
- Kuru, N. (2017). Otomotiv Yansanayi Firmasında Yapay Sinir Ağları İle Talep Tahmini. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- McCulloch, W. S., Pitts, W. (1943). A Logical Calculus of the Ideas Immanent in Nervous Activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.
- Meydan, Y. A. (2007). Talep Tahmin Yöntemleri ve Orta Ölçekli Bir İşletmede Uygulaması. Yüksek Lisans Tezi, İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Mijwil, M. M. (2018). Artificial Neural Networks: Advantages and Disadvantages. *Mesopotamian Journal of Big Data*. 2021(29-31). DOI: <https://doi.org/10.58496/MJBD/2021/006>
- Öztemel, E. (2003). *Yapay Sinir Ağları* (1. Baskı). İstanbul: Papatya Yayıncılık.
- Öztemel, E. (2012). *Yapay Sinir Ağları* (3. Baskı). İstanbul: Papatya Yayıncılık.
- Panchal, G., Ganatra, A., Kosta, Y. P., Panchal, D. (2011). Behaviour Analysis of Multilayer Perceptrons with Multiple Hidden Neurons and Hidden Layers. *International Journal of Computer Theory and Engineering*, 3(2), 332-337.
- Pham, D. T., Karaboga, D. (2000). *Intelligent Optimisation Techniques: Genetic Algorithms, Tabu Search, Simulated Annealing and Neural Networks* (1 th ed.). Londra: Springer.
- Popović, Ž., Brbaklić, B., Knežević, S. (2017). A Mixed Integer Linear Programming Based Approach for Optimal Placement of Different Types of Automation Devices in Distribution Networks. *Electric Power Systems Research*, 148, 136-146.
- Qamar, R. (2023). Artificial Neural Networks: An Overview. *Mesopotamian Journal of Computer Science* 2023(130-139). DOI:10.58496/MJCSC/2023/015

- Rosenblatt, F. (1958). The Perceptron: A Probabilistic Model for Information Storage and Organization in the Brain. *Psychological Review*, 65(6), 386-408.
- Rumelhart, D. E., Hinton, G. E., Williams, R. J. (1986). Learning Representations by Back-propagating Errors. *Nature*, 323(6088), 533-536.
- Sağanak, M. (2020). Depo Yeri Seçimi: Perakende Sektöründe Melez Çok Kriterli Karar Verme Uygulaması. *Journal of Yaşar University*, 15(59), 615-623.
- Sarı, M. (2016). Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması. Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Serttaş, Z. S. (2011). Türkiye’de Perakende Sektöründe Talebi Etkileyen Etmenler ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Shiruru, K., Rajesh, S. (2017). An Introduction to Artificial Neural Network. *International Journal Of Advance Research And Innovative Ideas In Education*, 1(5), 27-30.
- Solak, O. A. (2013). Türkiye’nin Toplam Petrol Talebi ve Ulaştırma Sektörü Petrol Talebinin Arima Modeli İle Tahmin Edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(3), 131-142.
- Söylemez, Y. (2020). Çok Katmanlı Yapay Sinir Ağları Yöntemi ile Altın Fiyatlarının Tahmini. *Sosyoekonomi*, 28(46), 271-291.
- Şenol, D. (2022). Yapay Sinir Ağları İle Kripto Para Tahmini. Yüksek Lisans Tezi, Sakarya Üniversitesi, Fen Bilimleri Enstitüsü, Sakarya.
- Tolon, M., Tosunoğlu, S. (2008). Yapay Sinir Ağları: Mimari ve Uygulamalar. *Türkiye Bilişim Dergisi*, 14(3), 45-50.
- Tomar, A., Gaur, P., Jin, X. (2023). *Prediction Techniques for Renewable Energy Generation and Load Demand Forecasting*. Lecture Notes in Electrical Engineering. Singapore: Springer Nature.
- Tran, T. H., Nagy, G., Nguyen, T. B. T., Wassan, N. A. (2018). An Efficient Heuristic Algorithm for the Alternative-fuel Station Location Problem. *European Journal of Operational Research*, 269, 159-170.
- Uçarsu, O. (2022). Yapay Sinir Ağları Kullanarak Dolar Kuru Gelecek Değer Tahmini Yapılması. Yüksek Lisans Tezi, Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Kocaeli.
- Ulucan, E., Kızılırmak, İ. (2018). Konaklama İşletmelerinde Talep Tahmin Yöntemleri: Yapay Sinir Ağları ile İlgili Bir Araştırma. *Seyahat ve Otel İşletmeciliği Dergisi*, 15(1), 89-101. DOI: <https://doi.org/10.24010/soid.415343>

- URL-1: <https://www.ibm.com/think/topics/supervised-vs-unsupervised-learning> (Ziyaret tarihi: 20 Eylül 2024).
- URL-2: <https://www.endeksa.com/tr> (Ziyaret tarihi: 22 Eylül 2024).
- Üstüner, E. (2019). Uluslararası Düzeyde Fabrika Kuruluş Yeri Seçimine Yönelik Bir Yaklaşım. Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Wang, B. C., Qian, Q. Y., Gao, J. J., Tan, Z. Y., Zhou, Y. (2021). The Optimization of Warehouse Location and Resources Distribution for Emergency Rescue Under Uncertainty. *Advanced Engineering Informatics*, 48(2021), 101278.
- Winston, L. W. (1994). *Operations Research - Applications and Algorithms* (4th ed.). California: Duxbury Press.
- Xu, S., Chen, L. (2008). A Novel Approach for Determining the Optimal Number of Hidden Layer Neurons for FNN's and its Application in Data Mining. *5th International Conference on Information Technology and Applications*, Queensland, Australia, 23-26 Haziran 2008.
- Yabar, E., Aydın, M. C. (2020). Dalgacık Dönüşümlü Yapay Sinir Ağlarıyla Günlük Akım Serilerinin Tahmini. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 9(2), 943-951.
- Yadav, N., Yadav, A., Kumar, M. (2015). *An Introduction to Neural Network Methods for Differential Equations* (1th ed.). Berlin: Springer Dordrecht.
- Yapıcı, S., Yumuşak, R., Eren, T. (2020). Çok Kriterli Karar Verme Yöntemleri ile Medikal Depo Yer Seçimi. *Trakya Üniversitesi İktisadi ve İdari Bilimler Fakültesi E-Dergi*, 9(2), 203-221.
- Yılmaz, A. (2020). Yapay Sinir Ağlarının Bir Taksonomisi. Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, İstanbul.
- Yuan, M., Zhang, Q., Wang, B., Liang, Y., Zhang, H. (2019). A Mixed Integer Linear Programming Model for Optimal Planning of Bicycle Sharing Systems: A Case Study in Beijing. *Transportation Research Part C*, 47(2019), 101515.
- Yücesoy, M. (2011). Temizlik Kağıtları Sektöründe Yapay Sinir Ağları İle Talep Tahmini. Yüksek Lisans Tezi, Fen Bilimleri Enstitüsü, İstanbul.
- Zontul, M., Yangın, A. (2017). Yapay Sinir Ağı Teknikleri Kullanarak Eğitim Yayıncılığı Sektöründe Veri Madenciliği. *AURUM Mühendislik Sistemleri ve Mimarlık Dergisi*, 1(2), 1-15.

KİŞİEL YAYIN VE ESERLER

Vural, M. A. (2024). Forecasting renewable energy production capacities with Python.
International Marmara Science and Social Sciences Congress, Kocaeli
Üniversitesi Anıtpark Kampüsü, Kocaeli, Türkiye, 29-30 Kasım 2024.



ÖZGEÇMİŞ

İlk, orta ve lise öğrenimini İstanbul’da tamamladı. 2018 yılında İstanbul Üniversitesi Mühendislik Fakültesi Endüstri Mühendisliği Bölümü’nden mezun oldu. Mezuniyetinin hemen ardından bir kimya fabrikasında Endüstri Mühendisi olarak profesyonel kariyerine adım attı. Çalıştığı firmada farklı departmanlarda görev alarak geniş bir deneyim kazandı ve yöneticilik pozisyonuna yükseldi. 2022-2025 yılları arasında Kocaeli Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda yüksek lisans eğitimini tamamladı.

