



**T.C.
İSTANBUL ÜNİVERSİTESİ-CERRAHPAŞA
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ**



[DOKTORA TEZİ]

**[YAPAY SİNİR AĞLARI KULLANILARAK HAVAYOLU BİLET
FİYATLARININ DİNAMİK OLARAK BELİRLENMESİ |**

[İsmail KOÇ]

**[DANIŞMAN
Dr. Öğr. Üyesi Emel ARSLAN]**

[Bilgisayar Mühendisliği Anabilim Dalı |

[Bilgisayar Mühendisliği Programı |

[İSTANBUL-2021]

Bu çalışma, 26.08.2021 tarihinde aşağıdaki jüri tarafından Bilgisayar Mühendisliği Anabilim Dalı, Bilgisayar Mühendisliği Programında Doktora tezi olarak kabul edilmiştir.

Tez Jürisi

Dr. Öğr. Üyesi Emel ARSLANI (Danışman)
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Prof. Dr. Sabri ARIK
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Doç. Dr. Neyir ÖZCAN SEMERCİ
Uludağ Üniversitesi
Mühendislik Fakültesi

Prof. Dr. Ahmet Sertbaş
İstanbul Üniversitesi-Cerrahpaşa
Mühendislik Fakültesi

Doç. Dr. Akhan Akbulut
İstanbul Kültür Üniversitesi
Mühendislik Fakültesi

|20.04.2016 tarihli Resmî Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince; Bu Lisansüstü teze, İstanbul Üniversitesi-Cerrahpaşa’nın abonesi olduğu intihal yazılım programı kullanılarak Lisansüstü Eğitim Enstitüsü’nün belirlemiş olduğu ölçütlere uygun rapor alınmıştır. |

ÖNSÖZ

Bu çalışma, İstanbul Üniversitesi-Cerrahpaşa Lisansüstü Eğitim Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı 'nda yapılan **“Yapay sinir ağları kullanılarak havayolu bilet fiyatlarının dinamik olarak belirlenmesi”** adlı doktora tez çalışmasını içermektedir.

Yüksek lisans tez çalışmalarım boyunca gösterdiği her türlü destek ve yardımlarından dolayı çok değerli hocalarım, Sayın Prof. Dr. Sabri ARIK ve Sayın Doç. Dr. Neyir ÖZCAN SEMERCİ ile danışman hocam Sayın Yrd. Doç. Dr. Emel ARSLAN'a en içten dileklerimle teşekkür ederim.

Ağustos 2021

İsmail Koç



İÇİNDEKİLER

Sayfa No

ÖNSÖZ	iv
İÇİNDEKİLER.....	v
ŞEKİL LİSTESİ	vii
SİMGE VE KISALTMA LİSTESİ.....	ix
ÖZET	xii
SUMMARY	xiv
1. GİRİŞ.....	1
2. GENEL KISIMLAR.....	7
2.1. SABİT FİYATLAMADAN DİNAMİK FİYATLAMAYA	7
2.2. DİNAMİK FİYATLAMA	8
2.3. DİNAMİK FİYATLANDIRMANIN BAŞARILI OLMA KOŞULLARI.....	9
2.3.1. Koşul 1: Müşteriler Ödeme İstekliliklerinde Heterojen Olmalıdır.....	9
2.3.2. Koşul 2: Pazar Bölümlere Ayrılabilir Olmalıdır	10
2.3.3. Koşul 3: Sınırlı Arbitraj	12
2.3.4. Koşul 4: Bölümleme ve Politika Maliyetinin Özelleştirme Nedeniyle Geliri Aşmaması Gerekir	12
2.3.5. Koşul 5: Algılanan Adalet Kavramları İhlal Edilmemelidir	13
2.4. DİNAMİK FİYATLANDIRMADA KULLANILAN MODELLER	15
2.4.1. Envantere Dayalı Modeller.....	16
2.4.2. Veriye Dayalı Modeller	18
2.4.3. Açık Artırmaya Dayalı Modeller.....	19
2.4.4. Oyun Teorik Modelleri	20
2.4.5. Makine Öğrenimi Tabanlı Modeller.....	22
2.4.5.1. Tek Bir Öğrenme Aracılı Modeller	22
2.4.5.2. Birden Çok Öğrenme Aracılı Modeller	24
2.5. MAKİNE ÖĞRENMESİ	26
2.5.1. Neden Makine Öğrenmesi	26
2.5.2. Makine Öğrenmesi Nedir	26
2.5.3. Makine Öğrenme Modelleri	27
2.5.3.1. Regresyon	29

2.5.3.2. Benzerliğe Dayalı Algoritmalar	29
2.5.3.3. Düzenleştirme Yöntemi.....	30
2.5.3.4. Karar ağacı.....	30
2.5.3.5. Bayes Modelleri.....	30
2.5.3.6. Çekirdek Yöntemleri	31
2.5.3.7. Kümeleme Yöntemleri	31
2.5.3.8. Birliktelik Kuralı	31
2.5.3.9. Yapay Sinir Ağı.....	32
2.5.3.10. Derin Öğrenme	32
2.5.3.11. Boyutsal küçülme	32
2.5.3.12. Topluluk Yöntemleri	33
2.5.3.13. Makine Öğrenimini Kullanan Sektörler	34
2.6. HAVAYOLU GELİR YÖNETİMİ.....	36
2.7. HAVAYOLU BİLET FİYAT TAHMİNLEMESİ.....	38
2.8. HAVAYOLU GİDERLERİ VE KARLILIK.....	40
2.9. UÇAK BİLET FİYATININ BELİRLENMESİ VE REGRESÖRLER	44
3. MALZEME VE YÖNTEM.....	47
3.1. VERİ	47
3.2. YÖNTEM	49
3.3. ÖN İŞLEME	51
3.4. ARAÇLAR	55
3.5. MODELLER.....	55
3.6. İSTATİSTİKİ PERFORMANS KRİTERLERİ.....	57
4. BULGULAR.....	60
5. TARTIŞMA VE SONUÇ	69
KAYNAKLAR.....	71
EKLER	80
Ek1. IMV-LSTM Kaynak Kodu.....	80
Ek2. VBS IMV-LSTM Kaynak Kodu.....	85
ÖZGEÇMİŞ	93

ŞEKİL LİSTESİ

	Sayfa No
Şekil 2.1: Makine Öğrenmesi modelleri.....	29
Şekil 2.2: Dinamik fiyatlandırma.	40
Şekil 2.3: Düşük sezon için kümülatif gelir grafiği örneği.....	43
Şekil 2.4: Yüksek sezon için kümülatif gelir grafiği örneği.....	43
Şekil 2.5: İstanbul kalkışlı güzergahların RASK-CASK değer karşılaştırmaları.....	44
Şekil 3.1: Düşük sezon için satış grafiği.....	48
Şekil 3.2: Yüksek sezon için satış grafiği.....	48
Şekil 3.3: Havayolu ve üç rakibi tarafından IST'den DUS'a uçulan günler.	49
Şekil 3.4: Bu çalışmanın akış diyagramı.	50
Şekil 3.5: Aykırı değerler grafiği.....	52
Şekil 3.6: Veri kümeleri ve bölümlenmeleri.	53
Şekil 3.7: Ham verilerle son 400 tahmin.	54
Şekil 3.8: Yuvarlatılmış verilerle son 400 tahmin.	54
Şekil 3.9: Veri yığıtlarının (batch) ayarlanması.	58
Şekil 3.10: Her yığıtın kendi uzunluğu ve geriye bak kaydırması vardır.....	58
Şekil 4.1: VBS IMV-LSTM Regresyon katsayısı sayısal değerleri.	62
Şekil 4.2: Veri kümesi Smoothed için zaman adımı 2'ye göre VBS IMB-LSTM'nin ısı haritası.	64
Şekil 4.3: Elde edilen fiyat koridorları ve gerçek değerler.....	68

TABLO LİSTESİ

	Sayfa No
Tablo 2.1: Havayolları maliyetlerinin yapısı.	41
Tablo 2.2: Uzun ve kısa mesafeli havayollarının zıt maliyet yapısı, 2007 mali yılı.	42
Tablo 2.3: Havayolu işletme maliyetlerini etkileyen faktörler.	42
Tablo 2.4: Dinamik bilet fiyatlandırma için kullanılan özellikler.	46
Tablo 3.1: 20 Haziran 2017 uçuş tarihi için örnek bir gözlem verisi.	51
Tablo 3.2: Augmented Dickey-Fuller tek kök (unit root) test.	53
Tablo 3.3: Kullanılan kütüphaneler.	55
Tablo 4.1: VBS IMV-LSTM hiperparametre ayarları.	60
Tablo 4.2: VBS IMV-LSTM'de çıktı hesaplama formülleri.	61
Tablo 4.3: Ampirik analiz.	63
Tablo 4.4: IMV-LSTM ve VBS IMV-LSTM ile çeşitli zaman aralıklarıyla deneyler.	66
Tablo 4.5: IMV-LSTM ve VBS IMV-LSTM ile çeşitli batch size değerleri ile deneyler.	67

SİMGE VE KISALTMA LİSTESİ

Simgeler

Açıklama

$\oplus$	: Birleştirme işlemi.
$\odot$	: Eleman bazlı çarpma işlemi.
$\otimes$	: The tensor-dot operation. Product of two tensors along an axis.
σ	: Lojistik sigmoid işlevi.
f_t	: forget gate – t zamanında unutma kapısı.
i_t	: input gate – t zamanında girdi kapısı.
o_t	: output gate – t zamanında çıktı kapısı.
c_t	: state – yapay sinir hücresinin t zamanındaki durumu.

Kısaltmalar

Açıklama

2D	: Two Dimentional – İki Boyutlu.
ACMI	: Aircraft Crew Maintenance Insurance – Uçak Mürettebat Bakım Sigorta.
AODE	: Averaged One-Dependence Estimators - Ortalamalı Tek Bağımlılık Tahmincileri.
ARIMA	: Autoregressive Integrated Moving Average - Otoregresif Entegre Hareketli Ortalama.
ARIMAX	: Autoregressive Integrated Moving Average with Exogenous Variables - Eksojen Değişkenlerle Otoregresif Entegre Hareketli Ortalama.
ARMA	: Autoregressive Moving Average - Otoregresif Hareketli Ortalama.
BBN	: Bayesian Belief Network - Bayes İnanç Ağı.
BSLP	: Base Stock List Price – Baz Stok Liste Fiyatı.
CART	: Classification and Regression Tree - Sınıflandırma ve Regresyon Ağacı.
CASK	: Cost per Available Seat-Kilometer - Kullanılabilir Koltuk Kilometre Maliyeti.
CNN	: Cellular Neural Network – Hücresel Sinir Ağı.
CPU	: Central Processing Unit – Merkezi İşleme Ünitesi
CSSA	: Chaotic Salp Swarm Algorithm - Kaotik Salp Sürüsü Algoritması.
DA-RNN	: Dual Attention Recurrent Neural Network - Çift Aşamalı Dikkat Temelli Tekrarlayan Sinir Ağı.
DBN	: Deep Belief Networks - Derin İnanç Ağları.

DNN	: Dynamic Neural Network – Dinamik Sinir Ağı.
DOC	: Direct Operating Cost - Doğrudan İşletim Maliyetleri.
DUS	: Düsseldorf.
DVD	: Digital Versatile Disc - Dijital Çok Yönlü Disk.
EFA	: Exploratory Factor Analysis - Açıklayıcı Faktör Analizi.
EWT	: Ampirical Wavelet Transform - Ampirik Dalgacık Dönüşümü.
GBM	: Gradient Boosting Machines - Gradient Güçlendirme Makineleri.
GDS	: Global Distribution System - Küresel Dağıtım Sistemi.
GPU	: Graphics Processing Unit – Grafik İşleme Ünitesi.
GRU	: Gated Recurrent Unit - Geçitli Tekrarlayan Ünite.
ID3	: Iterative Dichotomiser 3 - Yinelemeli Dikotomizer 3.
IMV-LSTM	: Interpretable Multi-Variable Long Short-Term Memory - Yorumlanabilir Çok Değişkenli Uzun Kısa Süreli Bellek.
IOC	: Indirect Operating Cost - Dolaylı İşletim Maliyeti.
IST	: İstanbul.
KNN	: K-Nearest Neighbor – K-En Yakın Komşu.
LASSO	: Least Absolute Shrinkage and Selection Operator - En Küçük Mutlak Büzülme ve Seçim Operatörü.
LDA	: Linear Discriminate Analysis - Doğrusal Ayrım Analizi.
LOESS	: Locally Estimated Scatterplot Smoothing - Yerel Olarak Tahmin Edilen Dağılım Grafiği Yumuşatma.
LSTM	: Long Short-Term Memory - Uzun Kısa Süreli Bellek.
LVQ	: Learning Vector Quantization - Vektör Nicelemeyi Öğrenme.
MAPE	: Mean Absolute Percentage Error - Ortalama Mutlak Yüzde Hatası.
MARS	: Multivariate Adaptive Regression Splines - Çok Değişkenli Uyarlanabilir Regresyon Uzanımları.
MDS	: Multi-Dimensional Scaling - Çok Boyutlu Ölçekleme.
NARX	: Nonlinear Autoregressive Exogenous - Doğrusal Olmayan Otoregresif Eksojen
NRIM	: No Replenishment of Inventory – Independent demands – Myopic Customers ; Taleplerin Yenilenmemesi – Bağımsız Talepler – Miyop Müşteriler.
NRIS	: No Replenishment of Inventory – Independent demands – Strategic Customers ; Taleplerin Yenilenmemesi – Bağımsız Talepler – Stratejik Müşteriler.
NSA	: Nonstationary Environments - Durağan Olmayan Ortamlar.
PCA	: Principle Component Analysis - Temel Bileşen Analizi.

PLS	: Partial Least Squares - Kısmi En Küçük Kareler.
RASK	: Revenue per Available Seat-Kilometer - Kullanılabilir Koltuk Kilometresi Başına Gelir.
RBF	: Radial Basis Function - Radyal Temel Fonksiyonu.
RBN	: Restricted Boltzmann Machine - Kısıtlı Boltzmann Makinesi.
RIM	: Replenishment of Inventory – Independent demands – Myopic Customers ; Taleplerin Yenilenmesi – Bağımsız Talepler – Miyop Müşteriler.
RMSE	: Root Mean Square Error - Kök Ortalama Kare Hatası.
RMSPE	: Root Mean Square Percentage Error - Kök Ortalama Kare Yüzde Hatası.
RNN	: Recurrent Neural Network - Tekrarlayan Sinir Ağı.
SOM	: Self-Organizing Map - Kendi Kendini Düzenleyen Harita.
SVM	: Support Vector Machine - Destek Vektör Makinesi.
SVR	: Support Vector Regression - Destek Vektör Regresyonu.
VBS IMV-LSTM	: Variant Batch Size Interpretable Multi-Variable Long Short-Term Memory – Değişken Yığıt Boyutlu Yorumlanabilir Çok Değişkenli Uzun Kısa Süreli Bellek
YSA	: Yapay Sinir Ağları.

ÖZET

[DOKTORA TEZİ]

[YAPAY SİNİR AĞLARI KULLANILARAK HAVAYOLU BİLET FİYATLARININ DİNAMİK OLARAK BELİRLENMESİ]

[İsmail KOÇ]

İstanbul Üniversitesi-Cerrahpaşa

Lisansüstü Eğitim Enstitüsü

[Bilgisayar Mühendisliği Anabilim Dalı]

[Danışman: Dr. Öğr. Üyesi Emel ARSLAN]

Havayollarının ortalama bilet fiyatları son yıllarda sürekli düşmektedir. Bu durum sadece yurdumuz için değil özellikle Avrupa ve Amerika için de geçerlidir. Üstelik bu durumun hem dış hatlarda hem de iç hatlarda olduğu gözlenmektedir. Bilet gelirleri havayollarının en önemli gelir kaynağı olduğu için artan rekabet gibi unsurlardan dolayı sürekli düşüşte olması, bilet fiyatlarının tespitinin önemini artırmaktadır. Bilet fiyatlarının belirlenmesinde sistematik yaklaşımların zayıf kaldığı ve insan yargısının önemli bir etken olduğu ortaya çıkmaktadır. Bunların yanında bilet fiyatlarının belirlenmesinde birçok faktör etkindir. Dolayısı ile geliştirilmeye çalışılan sistematik yaklaşımlar düşük istatistiki perfomans değerleri üretebilmektedirler.

Bu çalışmada bilet fiyatlarının belirlenmesinde etkili olan etkenler araştırılmış ve Gelir Yönetimi için kullanılabilir Karar Destek Sistem modeli üretilmiştir. Literatürdeki birçok çalışma ve ürünlerin gelir yükseltmeyi hedeflemesinin aksine bu çalışma kar yükseltmeyi hedeflemektedir. Havayolları giderleri araştırılmış ve hedef gelir ile kullanılabilir koltuk kilometre maliyet (CASK) değeri özellikleri ilk kez araştırmaya dahil edilmiştir. Bu çalışmada Türkiye’de oprasyonlarını yürütmekte olan hem yurt içi hem yurt dışı planlı ve charter uçuşlar yapan bir havayolunun gerçek değerleri kullanılmıştır. Modelin en iyi kar üreten verilerden öğrenebilmesi için elde edilen verilerden en iyi kar performansı üretmiş olan veriler ayrıştırılmış ve model eğitiminde kullanılmıştır. Veri kalitesini yükseltmek amacıyla aykırı veriler ayıklanmış ve her aşamada elde edilen veriler farklı veri setlerinde toplanarak ayrı ayrı incelenmiştir. Fiyat dalgalanmsından kaynaklı olumsuzlukları öngörebilmek amacıyla eğilim (trendline) verisi de oluşturulmuştur. Bütün bu çalışmalar geliştirilen bir modelin yanında diğer

farklı altı modele uygulanmış ve altı farklı istatistiksel performans değerlendirme kriterine göre test edilmiştir.

Bu çalışmada üzerinde çalışan veri, sürekli zaman serisi olarak değil örtüşen pencereler olarak değerlendirilmiştir. Bu veri setlerini üzerinde statik değil değişken yığıt boyutu hiperparametresine dayalı yeni bir model geliştirilmiş ve kullanılmıştır. Veri setleri üzerindeki bu yeni yaklaşım ve geliştirilen yeni model diğer modellere göre daha başarılı performans kriter değerleri üretmiştir.

Önerilen model ile insan yargısının azaltıldığı yüksek performans kriterleri üreten bir Karar Destek Sistem modeli oluşturulmuştur. Bu model havayolu sektörünün yanısıra örtüşen pencere veri yapısına sahip diğer sektörlerde de kullanılabilir.

Ağustos 2021, 109. sayfa.

Anahtar kelimeler: Havayolu, hava ulaşımı, Dinamik bilet fiyatlandırma, Yapay sinir ağları, Derin Öğrenme (Deep Learning), Zaman serileri analizi, Tahminleme, Uzun Kısa-Süreli Bellek

SUMMARY

Ph.D. THESIS

DYNAMIC TICKET PRICING USING ARTIFICIAL NEURAL NETWORKS

İsmail KOÇ

Istanbul University-Cerrahpasa

Institute of Graduate Studies

Department of Computer Engineering

Supervisor: Assist. Prof. Dr. Emel ARSLAN

Average ticket prices of airlines have been falling continuously in recent years. This is true not only for our country, but also for Europe and America. Moreover, this situation is observed both in international and domestic lines. Since ticket revenues are the most important source of income for airlines, the fact that they are constantly decreasing due to factors such as increasing competition increases the importance of determining ticket prices. It turns out that systematic approaches in determining ticket prices are weak and human judgment is an important factor. In addition, many factors affect the determination of ticket prices. Therefore, systematic approaches that are tried to be developed can produce low statistical performance values.

In this study, the factors affecting the determination of ticket prices were investigated and a Decision Support System model that could be used for Revenue Management was produced. Contrary to the fact that many studies and products in the literature aim to increase income, this study aims to increase profits. Airline expenses were researched and the characteristics of target revenue and available seat kilometer cost (CASK) value were included in the research for the first time. In this study, the actual values of an airline operating both domestic and international scheduled and charter flights in Turkey were used. In order for the model to learn from the data that produced the best profit, the data that produced the best profit performance from the obtained data were separated and used in model training. In order to increase the data quality, outlier data were removed and the data obtained at each stage were collected in different data

sets and analyzed separately. Trendline data was also created in order to predict the negative effects of price fluctuations. All these studies were applied to six different models besides one developed model and tested according to six different statistical performance evaluation criteria.

In this study, the data working on it were evaluated as overlapping windows, not as a continuous time series. A new model based on variable batch size hyperparameter, not static, was developed and used on these datasets. This new approach on the datasets and the new model developed produced more successful performance criterion values than other models.

With the proposed model, a Decision Support System model was created that produces high performance criteria in which human judgment is reduced. This model can be used in the airline industry as well as in other industries with overlapping window data structures. |

August 2021, [109] pages.

Keywords: Airline, Air Transportation, Dynamic Ticket Pricing, Artificial Neural Networks, Deep Learning, Time Series Analysis, Forecasting, Long Short-Term Memory |

1. GİRİŞ

Havayolu yöneticilerinin, tamamen kontrol edebildikleri koltuk kapasitesi arzını, kontrol edemedikleri taleple eşleştirmeleri gerekir. Gelir yönetiminin tanımı, koltuk envanteri olan sınırlı kapasiteli bir üründen maksimum kar elde etmek için ürünü doğru müşteriye doğru zamanda ve doğru fiyatla satmak olabilir. Gelir yönetimi, özellikle havacılık sektöründe artan rekabet, düşük maliyetli havayollarının pazara girmesi, karar destek sistemlerinin sürekli gelişmesi ve bilgisayar bilimi ile son yıllarda büyük ilgi gören bir disiplindir. Ken Littlewood'un (1972) ilk kez bir yöntem sunmasından bu yana araştırmacılar tarafından birçok çözüm modeli ve yaklaşım geliştirilmiştir.

Son yıllarda, havayolu endüstrisi yüksek bir büyüme oranı yaşadı. Ancak karlılık marjinal kaldı. Maliyet farklılıklarının belirlenmesi, havayolları için kritik bir konudur. Bilet fiyatları sektörün bilinen tarihi boyunca düşmektedir ve son yirmi yılda ortalama yüzde 2 oranında düşmeye devam etmektedir. Saxon ve Weber (2017), daha büyük uçakların, yeni teknolojilerin ve daha verimli operasyonların bir havayolu şirketinin maliyetini düşürdüğünü belirtmiştir. Cook (2014), havayollarının fiyatlandırma ve gelir yönetiminde en iyi uygulamayı yaptıklarını vurgulamıştır çünkü talebi tahmin etmek, rakiplerin fiyatlarını izlemek ve bunlara yanıt vermek ve envanter kullanılabilirliğini yönetmek için rekabet avantajı ve daha yüksek getiri sağlayan gelişmiş sistemler geliştirmeye yoğun bir şekilde yatırım yapmışlardır.

Fedorco ve Hospodka (2013) çalışmalarında, farklı pazarlarda ve farklı zaman dilimlerinde uçak bileti fiyatlarının izlenmesine dayalı fiyatlandırma stratejilerinin değerlendirilmesine odaklanmaktadır. Makalede, pazar türü, rakipler, yoğun dönem, sezon, yakıt maliyetleri ve çevresel maliyetler gibi uçak bileti fiyatlarını etkileyen faktörler dikkate alınmaktadır. Ayrıca makalelerinde, geleneksel ve düşük maliyetli havayollarının fiyatlandırma stratejilerindeki farklılıkları, farklı yönetim türlerini tartışmaktadır. Fiyatlandırma stratejilerini ve dolayısıyla gerçek bilet fiyatını etkileyen birçok faktör vardır. Pazar türü, yeni şirket tarafından dikkate alınması gereken çok önemli bir faktördür. İş amaçlı seyahat edenlerin daha büyük olduğu pazarda, şirket daha yüksek fiyatlarla daha iyi bir ürün sunmalıdır. Mevsimsellik ve yoğun dönem, dikkate alınması gereken diğer faktörlerdir. Taşıyıcı yaz ve kış aylarında aynı fiyatlandırma stratejisini uygulayamaz. Örneğin, Avrupa içinde seyahat talebinin düşük olduğu

kış aylarında, taşıyıcı, doluluk faktörünü artırmak için daha düşük gelir beklemeli ve daha fazla indirimli bilet sunmalıdır. Pik dönemler, bilet fiyatlarının önemli ölçüde değiştiği kısa vadeli olaylardır. Rasyonel fiyatlandırma stratejilerine sahip her taşıyıcı, yoğun dönemlerde, daha yüksek fiyatlara yanıt veren hava yolculuğu talebinin artmasını bekler. Bu nedenle, yeni giriş yapan taşıyıcı, kapasiteyi daha düşük verimle satmaktan kaçınmak için yoğun dönemlerde makul fiyatları önceden belirlemelidir. Artan fiyatlar ile taşıyıcı, fiyata duyarlı yolcuları düşük talep edilen uçuşlara kaydırmalı ve zamana duyarlı yolculara satılan biletlerden geliri artırmalıdır.

Gelir yönetimi yöntemlerini iyileştirmeyi taahhüt eden havayolları, stok kontrolünde koltuğun sadece birbiriyle ilişkili birkaç bileşeni içermediğini, aynı zamanda havayolu içindeki diğer işlevlerle de yakından ilişkili olduğunu bulmuşlardır (Belobaba, 1987). Havayolunun getiri yönetimi birimi içinde, karar destek araçlarında yapılan iyileştirmelerin, bu araçlar tarafından kullanılan veri girdilerinde ve ayrıca çıktıların koltuk envanteri kontrol kararlarını vermek için kullanılma yollarında karşılık gelen iyileştirmeler olmadan çok az değeri vardır. Gelişmiş araçlar ve matematiksel modeller, bunları kullanmak için yeterli sayıda eğitilmiş analist olmadan çok az değer taşır. Her şeyden önce, ilgili işlevlerle koordinasyon eksikliği, koltuk envanteri kontrolünün gelir maksimize etme hedeflerini baltalamaya hizmet ediyorsa, bu tür araçları geliştirmeye yönelik her türlü çaba boşa gider. Bu nedenle, bir havayolunun getiri yönetimine yapılan herhangi bir yatırımdan en iyi şekilde yararlanmak için üst yönetimin desteğiyle koordineli bir sistem yaklaşımı gereklidir.

Karar destek sistemlerinde iyileştirmeler nispeten kısa sürede gerçekleştirilebilir. Bir havayolu şirketi, çoğu rezervasyon sistemi tarafından depolanan muazzam miktardaki geçmiş rezervasyonları ve trafik verisini kullanmak için kendi bünyesinde bir karar destek sistemi satın alabilir veya geliştirebilir. Geçmiş verileri depolamanın yanı sıra rezervasyon sistemleri, koltuk envanteri kontrol sürecinin operasyonel merkezidir. Bununla birlikte, karar destek araçlarının geliştirilmesinin aksine, rezervasyon sistemi yeteneklerini değiştirmek ve bunları getiri yönetiminin ihtiyaçlarıyla daha fazla ilişkilendirmek, çoğu havayolu için orta vadeli bir hedeftir.

Koltuk envanteri kontrol yöntemlerini iyileştirmenin en karmaşık ve en uzun vadeli hedefi, gelecekteki rezervasyonları tahmin etmek ve uçak yükü gelirlerini optimize etmek için matematiksel karar modellerinin geliştirilmesidir. Karar analizi ve matematiksel programlama

araçları, gelir maksimizasyonu problemine çok uygundur. Buradaki zorluk, bu araçları koltuk envanteri kontrol bağlamına uyarlamak ve geçmiş veriler temelinde makul bir geçerlilikle kalibre edilebilecek pratik versiyonlar geliştirmektir.

Koltuk envanteri kontrolü için optimizasyon modelleri, kaçınılmaz olarak, gelecekteki uçuşlar için tahmini talep seviyeleri ve beklenen gelir tahminleri şeklinde girdi verilerini gerektirecektir. Geçmiş araştırmalardaki vurgu, optimizasyon rutinlerinin geliştirilmesi üzerindeyken, talep tahmini sorunu çok az ilgi görmüştür. Hava yolculuğu talebindeki doğal değişkenlik ve havayolu piyasalarının oynaklığı göz önüne alındığında, genelleştirilebilir ancak doğru tahmin modellerinin geliştirilmesi zor olacaktır. Bu durumdaki zorluk, gelecekteki talep seviyeleriyle ilişkili belirsizliği azaltmak için istatistiksel ve ekonometrik yöntemler uygulamaktır.

Brons ve diğ. (2002), fiyatlar hakkında veri mevcudiyeti, yolcu sayısı vb. gibi çeşitli sorunlar nedeniyle havacılıkta fiyat esnekliklerini tahmin etmenin oldukça zor olabileceğini bildirmiştir.

Lantseva ve diğ. (2015) ülkesi Rusya için bir çalışma yapmıştır. Bu çalışmada iki farklı piyasa incelenmiştir. Birincisi, hava yolculuğu politikasının yeterince gelişmiş olduğu Avrupa yönlerine hâkim uluslararası uçuşlar, ikincisi ise Rusya genelinde bölgesel ulaşım. Bazı önemli farklılıklar bulmuştur. Yabancı havayollarının oldukça iyi sunulduğu dış hat uçuşlarında, gözlemlenen fiyatlandırma davranışı daha önceki çalışmalarda tartışılana oldukça yakın bulunmuştur. Bununla birlikte, yerel uçuşlarda durum tartışmalı hale gelmiş ve ek sorgulamalar gerektirmiştir. Bunun nedeni belki de Rusya hava yolculuğu pazarındaki rekabetin uluslararası pazarlardaki kadar yüksek olmamasıdır. Dünyada popüler olan “düşük maliyetli” taşıyıcılar uzun zamandır uluslararası uçuşların ayrılmaz bir parçası olmuştur, ancak Rusya için bu bir yenilik olmaya devam etmektedir. Ayrıca, tekeller önemli bir rol oynamaktadır.

Burger ve Fuchs (2005) makalelerinde, havayolu endüstrisi için dinamik bir fiyatlandırma stratejisinin ekonomik etkilerini incelemektedir. Belirli bir uçuştaki bir koltuğun, dinamik olarak fiyatlandırılmaya uygun, tipik bir bozulabilir mal olduğu gösterilmiştir. Dinamik bir fiyatlandırma stratejisinin uygulanması, rakiplerin gelir yönetimi stratejisine bağlı olarak, gelirler üzerinde nötr veya olumlu bir etkiye sahiptir. Ayrıca, dinamik bir fiyatlandırma stratejisi yalnızca geliri etkilemekle kalmaz, aynı zamanda bir havayolunun maliyet yapısını da etkiler ve dolayısıyla doğrudan süreç karmaşıklığında ve işlem maliyetinde bir azalmaya yol

açar. Bu nedenle, dinamik fiyatlandırma, verimli bir çekme stratejisi için başlangıç noktası olduğunu kanıtlamaktadır. Dinamik bir fiyatlandırma stratejisi muhtemelen havayolu endüstrisi için yeni bir iş modeline yol açabilmektedir.

Havayollarının fiyat belirlemesini desteklemek için piyasada bazı ticari ürünler mevcuttur. Bununla birlikte, bu ürünler yalnızca geçmiş veriler girdi olarak verildiğinde literatürde tanıtılan çeşitli algoritmaları uygulamaktadırlar. Havayollarının güncel uygulama araştırması, koltuk envanter kontrolünün sistematik bir analize değil, daha çok insan yargısına dayandığını göstermektedir. Bununla birlikte, aynı şartlar altında, gelir yöneticileri tarafından belirli bir rota için belirlenen fiyat farklılık gösterebilir. Aynı uçuş için tayin edilen fiyat, farklı gelir yöneticilerine göre de değişebilir. Fiyat, rakip fiyat değişikliklerine göre değişebilir ve bu da koltuk kapasitesini ve yük faktörünü yönetmeyi daha zor hale getirir. Panik fiyat değişiklikleri, erken fiyat düşüşüne neden olabilir ve uçuşun toplam gelirini azaltabilir. Bilet fiyatı tahsisine katkıda bulunan gerekli özelliklerin olmaması ve geleneksel modeller ve yaklaşımlar düşük istatistiksel değerlendirme puanları üretmektedir.

Bu çalışma, uçak bilet fiyatlarının otomatik olarak belirlenmesine katkı üretmek üzere bir model üretebilmeyi hedeflemektedir. Bu çalışma için Türkiye de operasyonları yürütmekte olan ve düşük maliyetli havayolu olarak bilinen özel bir havayolu verileri ile çalışılmıştır. Bu kapsamda havayolunun süreçleri detaylı olarak incelenmiş ve Gelir Yönetimi Departmanı ile çok sayıda toplantılar yapılarak süreçler analiz edilmiştir.

Bu bağlamda bilet fiyatlarını belirlemede hangi faktörlerin etkin olduğu tespit edilmiştir. Literatürdeki diğer çalışmaların belirlediği faktörlere ek olarak özellikle maliyetin ve Hedef Gelir'in de göz ardı edilmemesi gereken faktörler olduğu sonuncuna ulaşılmıştır. Bu çalışmada bu faktör de dahil edilmiştir.

Literatürde sözü geçen faktörler ile yukarıda ifade edilen iki faktör ile ilgili söz konusu hava yolunun 15 Haziran 2017 ile 12 Haziran 2019 verileri toplanmıştır. Rakip havayollarının da fiyatlarını alabilmek için bu alanda faaliyet gösteren fiyat verilerini sağlayan ticari bir firma ile iletişime geçilmiştir. Firma, rakip firmaların günlük değil ama haftalık verileri vermeyi kabul etmiş ve sağlamıştır.

Çalışmanın faydalı bir sonuç üretebilmesi için görece istikrarlı bir uçuş hattı olan İSTANBUL-DÜSSELDORF seçilmiş ve bu hattın sadece tek uçuş verileri üzerinde çalışılmıştır. Fiyat istikrarı üzerinde olumsuz etki edebilecek gidiş – dönüş bilet fiyat verileri filtrelenmiştir.

Toplanan geçmiş verilerin her zaman en iyi gelir performansı üretmiş veriler olmayacağı düşünülmüştür. Bu nedenle geçmiş veriler gelir performansının yüksekliğine göre kendi içinde ikiye ayrılmıştır. Karlılık yaz aylarında yüksek olduğundan ve kış aylarında düşük olduğundan mevsimsel etki de göz önünde bulundurulmuştur. Mevsim etkiyi azaltabilmek için verilerin ikiye ayrılması işlemi her ay için ayrı ayrı yapılmıştır. Günlük bazlı etkiye arındırmak için de her uçuş günü yine kendi gününün verileri ile karşılaştırılmıştır. Örneğin Pazartesi verileri yine aynı ait diğer Pazartesi verileri ile karşılaştırılmıştır.

Yapılan ön analizlerde ham verilerin içinde oldukça yüksek sayıda aykırı veri olduğu sonucunu ulaşılmıştır. Bu aykırı verilerin varlığı oluşturulan ve üzerinde çalışılan modellerin performansı oldukça olumsuz etkilediği gözlenmiştir. Aykırı verilerin var olma nedeni uluslararası bilet tedariki sağlayan firmalar ve portallar, grup rezervasyonları, aynı hat üzerinde farklı Gelir Yönetim Uzmanlarının çalışması gibi etkenler gösterilebilir. Aykırı verilerin filtrelenmesine çalışılmış ve filtrelenmiş yeni veri setleri yeni veri gruplarında toplanmıştır. Filtreleme için uygulanan metot, trend çizgisine olan fiyat farkının değerinin belirli bir yüzde değerinden az olduğu gözlemdir. Fiyat dalgalanmasının etkisini görebilmek için eğilim dalgası da oluşturulmuştur. Oluşturulan modellerle yukarıda ifade edilen ham veri seti, filtrelenmiş veri setleri ve eğilimi gösteren veri setleri çalışılmıştır.

Çalışmada kullanmak üzere literatür incelenmiş ve üretilen modeller çalışılmıştır. En iyi performansı üretebilecek modellerin bile ürettikleri performans değerlerinin karar verme mekanizmasına yardımcı olabilecek yakınlıktan uzak olduğu tespit edilmiştir. Bunun nedenselliği araştırılmış ve buna göre farklı model geliştirilmiştir. Üretilen modelin ve yaklaşımın daha önce üretilen modellerden daha iyi istatistiki performans ürettiği gözlenmiştir.

Yeni yaklaşımda öncelikle verilerin örtüşen pencere yapısında olduğu gerçeği ile hareket edilmiştir. Öncelikle, daha önce çalışılmış ve en iyi performansı üretmiş olan Interpretable Multi-Variable Long Short-Term Memory (IMV-LSTM) -Yorumlanabilir Çok Değişkenli Uzun Kısa Süreli Bellek modeli üzerinde çalışılmıştır. Bu modelin verileri ele alış şekli değiştirilmiş ve örtüşen pencere yapısında veriler üzerinde çalışacak hale getirilmiştir. Yeni

yaklaşım ve yeni model, daha öncekilerden çok daha yüksek performans verileri üretmiştir. Yeni yaklaşım ve modelin verileri ile daha önce kullanılan modellerin ürettikleri sonuçlar tablo haline getirilmiş ve karşılaştırılmıştır.

Bunlara ek olarak yeni modelin ürettiği sonuçlar ile bilet fiyat tespitinde kullanılmak üzere kara mekanizması için bir fiyat aralığı tavsiyesi üretilmiştir. Güncel veriler ile model beslendiğinde modelin ürettiği fiyat aralığının daralacağına ve ileride aralık yerine doğrudan fiyat teklif edileceğine inanılmaktadır.



2. GENEL KISIMLAR

2.1.SABİT FİYATLAMADAN DİNAMİK FİYATLAMAYA

Fiyatlandırmada, malların pazarlanma ve satılma şeklini önemli ölçüde değiştirmeyi vaat eden bir eğilim var. Satıcılar artık bireysel müşteriler için uyarlanmış özel fırsatlar sunmakta ve doğru zamanda doğru müşteriye doğru fiyatı hesaplamaya başlamaktadırlar. Bu değişiklik büyük ölçüde ekonominin İnternet, kurumsal ağlar ve kablosuz ağlar aracılığıyla kablolanmasından kaynaklanmaktadır. Alıcılar artık ürünleri ve fiyatları hızlı ve kolay bir şekilde karşılaştırarak onları daha iyi bir pazarlık konumuna sokabilmektedir. Aynı zamanda teknoloji, satıcıların müşterilerinin satın alma alışkanlıkları, tercihleri, hatta harcama limitleri hakkında ayrıntılı veriler toplamasına izin vererek, ürünlerini ve fiyatlarını özelleştirebilmelerini sağlamaktadır. Geçmişte, menü maliyeti olarak bilinen fiyatların değişmesiyle ilişkili önemli bir maliyet vardı. Geniş bir ürün yelpazesine sahip bir şirket için fiyat ayarlamalarının distribütörlere, perakendecilere ve satış görevlilerine göre filtrelenmesi aylar alabilmektedir.

Ağ teknolojisinin ortaya çıkışı, menü maliyetini ve süresini neredeyse sıfıra indirdi. Alıcılar ve satıcılar elektronik dünyada etkileşime girdikçe, ortaya çıkan dinamik fiyatlar, ticareti yapılan ürün ve hizmetlerin gerçek piyasa değerini daha yakından yansıtmaktadır.

Özetle, elektronik ticarete sabit fiyatlandırmadan dinamik fiyatlandırmaya bir paradigma kaymasıyla sonuçlanan iki gelişme vardır (Bichler ve diğ., 2002).

1. Dinamik fiyatlandırmanın uygulanması için işlem maliyetleri şu şekilde düşürülmüştür:
 - a. İnsanların fiziksel olarak zaman ve mekanda bulunma ihtiyacını ortadan kaldırmak,
 - b. arama maliyetlerini azaltmak,
 - c. değişen fiyatların bildirilmesi menü maliyetlerinin düşürülmesi.
2. Artan belirsizlik ve talep oynaklığı, müşteri sayısının artmasına, rakip sayısının artmasına ve bilgi miktarının artmasına neden olmaktadır. Dinamik fiyatlandırmanın kendisi fiyat belirsizliğinin artmasına neden olmaktadır ve

şirketler bu değişken internet pazarlarında tek bir sabit fiyat kullanmanın etkisiz ve verimsiz olduğunu görmektedir.

2.2.DİNAMİK FİYATLAMA

Dinamik fiyatlandırma, bu müşterilerin bir ürün veya hizmete atfettikleri değere bağlı olarak fiyatların tüketicilere dinamik olarak ayarlanmasıdır (Reinartz, 2002). Literatürde dinamik fiyatlandırmayı tanımlamak için çeşitli alternatif terimler kullanılmıştır. Bunlara esnek fiyatlandırma ve özelleştirilmiş fiyatlandırma dahildir. Dinamik fiyatlandırma iki yönü içerir: (1) fiyat dağılımı ve (2) fiyat farklılaştırması. Fiyat dağılımı mekansal veya zamansal olabilir. Mekansal fiyat dağılımında, birkaç satıcı belirli bir ürünü farklı fiyatlarla sunar. Geçici fiyat dağılımında, belirli bir mağaza, satış zamanı ve arz-talep durumuna bağlı olarak zaman içinde belirli bir mal için fiyatını değiştirir. Dinamik fiyatlandırmanın diğer yönü, aynı ürün için farklı tüketicilere farklı fiyatların uygulandığı farklı fiyatlandırma veya fiyat ayrımcılığıdır. Burada üç tip vardır (Varian, 1996).

- Birinci derece (veya mükemmel) farklılaşma: Bir üretici, farklı çıktı birimlerini farklı fiyatlarla satar ve bu fiyatlar kişiden kişiye farklılık gösterebilir. Burada, malın her bir birimi, ona en çok değer veren kişiye, bu kişinin ürün için ödemeye razı olduğu maksimum fiyattan satılır. Üretici, her bir müşteri için maksimum ödeme istekliliğini belirlemek için yeterli bilgiye sahipse, bu yöntem, tüketici fazlasının tamamını piyasadan çekebilecektir.
- İkinci derece fiyat farklılaşması: Buna doğrusal olmayan fiyatlandırma da denir ve üreticinin farklı çıktı birimlerini farklı fiyatlarla satması, ancak aynı miktarda ürün alan her bireyin aynı tutarı ödemesi anlamına gelir. Bu nedenle fiyatlar, satın alınan ürünün miktarına bağlıdır, ancak satın alma işlemini kimin yaptığına bağlı değildir. Örnekler, miktar indirimlerini ve primleri içerir. Başka bir örnek kamu hizmetleridir; örneğin, elektriğin birim fiyatı genellikle ne kadar satın alındığına bağlıdır.
- Üçüncü derece fiyat farklılaşması: Üreticinin farklı kişilere farklı fiyatlara ürün satması, ancak belirli bir kişiye satılan her birim ürünün aynı fiyattan satması durumudur. Fiyat farklılaştırması, tüketici değerlemelerindeki farklılıklardan yararlanılarak sağlanır. Bir örnek grup fiyatlandırmasıdır (yaşlılar, öğrenciler vb.). Başka bir örnek telekom fiyatlandırmasıdır (işletmeler ve haneler için farklı fiyatlandırma).

Çoğu zaman, fiyat farklılaştırması, ürün farklılaştırması yoluyla sağlanır. İkincisi, ek nitelikler veya mevcut niteliklerin geliştirilmesi yoluyla elde edilir. Satıcılar, ürünleri farklılaştırarak, ürün ve hizmetlerinin ikame edilebilirliğini azaltabilir ve teklifleri belirli tüketicilerin veya pazar bölümlerinin gereksinimlerine göre özelleştirebilir. Hemen bir örnek, sattığı her bilgisayarın benzersiz olduğu, çünkü her alıcı tarafından uygulanan benzersiz seçim seçeneklerini yansıttığı Dell bilgisayarlarıdır. Diğer bir örnek, ürünlerin iade politikaları, iptal kısıtlamaları, hafta sonu konaklamaları vb. bazında farklılaştırıldığı havayolu endüstrisidir.

Elmaghraby ve Keskinocak (2003), dinamik fiyatlandırma yöntemlerini iki geniş kategoride sınıflandırır: Gönderilen fiyat mekanizmaları ve fiyat keşif mekanizmaları. Birinci kategori altında, bir ürün veya hizmet, satıcı tarafından belirlenen al ya da bırak fiyatıyla satılır. Gönderilen fiyatlar, satıcının satış zamanına, talep bilgilerine ve arz mevcudiyetine bağlı olarak fiyatları zaman içinde dinamik olarak değiştirmesi anlamında dinamik olabilir. Fiyat bulma mekanizmalarında fiyatlar bir ihale süreci ile belirlenir. Açık artırmalar hemen bir örnek sağlar.

Esnek fiyatlandırma ifadesi genellikle dinamik fiyatlandırmayı belirtmek için kullanılır. Bichler ve diğ. (2002) bu terimi daha geniş anlamda kullanırlar. Farklı fiyatlandırma (farklı alıcılar, beklenen değerlemelere göre farklı fiyatlar alırlar) ve dinamik fiyatlandırma (fiyatlar piyasa katılımcılarının tekliflerine dayanır) arasında ayrım yapar ve her ikisine de atıfta bulunmak için esnek fiyatlandırma terimini kullanırlar.

2.3.DİNAMİK FİYATLANDIRMANIN BAŞARILI OLMA KOŞULLARI

2.3.1. Koşul 1: Müşteriler Ödeme İstekliliklerinde Heterojen Olmalıdır

En temel koşul, müşterilerin aynı mal veya hizmetler için farklı fiyatlar ödemeye istekli olmalarıdır. Bazıları yüksek bir fiyat ödemeye hazırdır, diğerleri ise yalnızca mevcut en düşük fiyattan satın almaya istekli olacaktır. İstekli olma konusundaki bu farklılıklar, aşağıdakiler de dahil olmak üzere çeşitli şekillerde açıklanabilir: zamanın fırsat maliyeti, arama çabalarını genişletme ihtiyacı, farklı insanların üstlenmeye istekli olduğu ürün riski ve farklı marka adları ve değer algıları. Çoğu pazarda bu heterojenlik geçerlidir. Markalı ürünlerin ve jenerik ürünlerin bir arada bulunduğu yerlerde özellikle işaretlenmiştir (örneğin, birçok bakkaliye, giyim eşyası, lastik). Aynı durum, fiyat aralığının (belirli bir ürün için en düşük fiyattan en yüksek fiyata) geniş olduğu ve arama çabalarının ödüllendirildiği pazarlar için de geçerlidir.

Emtia gibi farklılaşmamış ürün pazarları, ödeme istekliliğinin çok fazla değişme ihtimalinin düşük olduğu yerlerin örnekleridir.

Soru, çevrimiçi bir ortamın bu fiyatlandırma sorunları üzerindeki etkisi nedir? Mevcut (sınırlı) ampirik kanıtlar, ödeme istekliliğinde daha fazla heterojenliğe işaret etmektedir. Bu tabii ki tüketicilerin internetten alışveriş yaparken artan fiyat duyarlılığından kaynaklanıyor. Örneğin, birçok çalışma, müşterilerin çevrimdışı alışverişe kıyasla çevrimiçi fiyatlara karşı daha yüksek bir duyarlılık sergilediğini göstermiştir (Shankar ve diğ. 1999, Smith ve diğ. 2001).

Dahası, bilgi hacmi ve nüfusun yalnızca bir kısmının çevrimiçi erişime sahip olması, ödeme istekliliğinde daha fazla heterojenliğe yol açar. Bu görüş, internetin daha düşük kar marjları ile daha rekabetçi pazarlara yol açmasının muhtemel olduğunu iddia eden Porter (2001) tarafından da yinelenmektedir.

2.3.2.Koşul 2: Pazar Bölümlere Ayrılabilir Olmalıdır

Birçok ürün pazarı, müşterilerin ödeme yapma istekliliğinde önemli ölçüde serbestlik sergilerken, fırsattan yararlanmak başka bir konudur. Örneğin, tüm müşterilere aynı muamele edildiğinden, hiçbir kitle pazarı fiyat özelleştirmesine uygun değildir. Bağlılık programları olmayan bakkallar bir örnek sunar:

Müşteri, belirli bir ürün için aynısını öder çünkü perakendecinin daha fazla ödemeye istekli olabilecek müşterileri tanıma yolu yoktur. 'Eski' ekonomideki firmalara iki faktör yardımcı olmuştur. Bunlardan biri, benzersiz bir müşteri ile tipik olarak belirli bir müşteri hesap numarası veya müşterinin adresi biçiminde bir bağlantı kurma yeteneğidir.

'Eski' ekonomi firmalarının müşterilerini segmentlere ayırmasına yardımcı olan bir diğer faktör de kendi kendini seçmektir. Birçok satın alma durumunda, tüketiciler kendilerini fiyat özelleştirmesi için hedef aday olarak tanımlayabilir. Örneğin, bir uçak bileti için önceden rezervasyon tarihini seçerek, müşteriler zamana göre esneklik derecelerini ve dolayısıyla kısmen ödeme istekliliklerini ortaya koyarlar.

Web, bir firmanın, özellikle internet üzerinden bireysel müşteri satın alımlarını takip ederek, ödeme istekliliği açısından bir pazarı segmentlere ayırma becerisini önemli ölçüde geliştirmiştir. Zaman içinde profiller oluşturmak, firmaların tüketicilerin fiyat duyarlılığını değerlendirmelerine ve ardından bireylere veya daha büyük olasılıkla, farklı derecelerde ödeme

istekliliği olan segmentlere pazarlama kampanyaları başlatmalarına olanak tanımıştır. Örneğin, fiyata duyarlı bir çevrimiçi market müşterisi ürünleri seçmeden önce her zaman fiyata göre sıralayabilirken, hassas olmayan müşteriler marka adı, beslenme içeriği veya başka bir fiyat dışı değişken tarafından yönlendirilen seçim stratejileri uygulayabilmektedir.

Ayrıca, ürün kategorisine göre ödenen ortalama fiyatları hesaplamak ve bunu zaman içinde ilişkilendirmek oldukça kolaydır. Bu bilgileri kullanarak süpermarket, indirim kuponlarına karşı yeni premium marka tanıtımları için alakalı hedef profilleri oluşturabilir.

Sözde düşünce seti pazarlamasıyla çok daha derin bir etki elde edilebilir. Oldukça küçük bir değerlendirme seti (oldukça büyük farkındalık setinin aksine), bir alışveriş yapanın alışveriş sepetine dahil etmek için neredeyse eşit olarak değerlendirebileceği ürünler grubudur. Alışveriş yapanlar, kategorideki ürünlerin bir rutin değerlendirme sürecinden geçtikten sonra, olası seçenekleri değerlendirme setine indiriyor. Örneğin, ambalajlı mal endüstrisindeki bedel setlerinin genellikle iki ila beş üründen oluştuğu gösterilmiştir. 'Eski' ekonomide pazarlamanın bu kadar verimsiz olmasının bir nedeni, tam da tüketicilerin dikkatleri kümesinin perakende yöneticileri tarafından bilinmemesidir. Satıcı tarafından tipik olarak bilinen tek şey, tüketicinin gerçekte seçtiği ve satın aldığı üründür. Bir mağaza, müşterinin düşünce seti hakkında bir şeyler bildiğinde, pazarlama çabasını çok daha hassas bir şekilde yönlendirebilir. Örneğin, bir dağ bisikleti için pazarda olan iki müşteri düşünülebilir. Her iki müşteri de seçimlerini, kalite odaklı bir kitlesel pazar bisiklet üreticisi olan TREK'in modeline daraltabilir. Sadece sonucu bilmek, alıcıları hiçbir şekilde ayırt edemez ve onlara eşit davranılırdı. Bununla birlikte, arama davranışları, seçtikleri bağlam hakkında son derece açıklayıcıdır. Tüketici A, birinci sınıf bir marka olduğu için o bisikleti seçmeye başlar. Tüketici B'nin tercihi, değer odaklı bir alışverişçi idi. Çıkarım şudur ki, A tüketicisinin ödeme istekliliği, muhtemelen B tüketicisinininkinden daha yüksektir.

İki alıcının bilgi arama ve göz atma yolunu izlemek, web'in bir yan ürünüdür. Değerlendirme seti aracılığıyla seçim bağlamını bilmek, yöneticilerin müşterilerinin ödeme istekliliğine ışık tutmasına olanak tanır. Bu nedenle, firmaların 'eski' ekonomide ödeme istekliliği hakkında bilgi elde edememesi, çevrimiçi dünyada dikkate alınan pazarlamayı kullanarak aniden çok daha az sorun haline gelir. Üstelik, herhangi bir ürün seçmeden bile, insanlar ürünler hakkında bilgi aradıklarında olduğu gibi, göz atma yolunu izlemek, değerlendirme seti hakkında çok değerli bilgiler verir.

2.3.3.Koşul 3: Sınırlı Arbitraj

Özel fiyatlandırmanın işe yaraması için üçüncü koşul, tüketicilerin arbitraj yapma kabiliyetinin sınırlı olmasıdır. Yani, bir ürünü daha düşük bir fiyata satın alan bir kişi, daha yüksek istekli müşterilere onu kar için yeniden satamaz. Bu koşul yoksa, firmaların fiyatta ayrımcılık yapma teşviki yoktur. Bununla birlikte, ucuz bir uçak bileti kısıtlamalarla yüklenir ve belirli bir kişiye yapılır, bu nedenle daha yüksek bir fiyata yeniden satılamaz. Diğer birçok kategoride arbitraj bir sorun değildir çünkü maliyet çabaya değmez.

Web, arbitraj kriterini değiştirmeden, internetin potansiyel arbitraj için koşulları etkin bir şekilde oluşturduğu bazı durumlar vardır.

Böylelikle, şeffaflık yaratarak, çevrimiçi ortamlar aslında mevcut iyi hazırlanmış fiyat özelleştirme planlarını ortadan kaldırmaya yardımcı olabilmektedir.

2.3.4.Koşul 4: Bölümleme ve Politika Maliyetinin Özelleştirme Nedeniyle Geliri Aşmaması Gerekir

Etkili bir fiyat özelleştirme planı için gerekli olan dördüncü kriter, makul bir uygulama maliyetidir. 'Eski' bir ekonomi bağlamında, birçok potansiyel fiyat özelleştirme planı bu nedenle baltalandı. Tanıtılamayacak kadar pahalıydılar. Havayolları muhtemelen uygulaması milyonlarca dolara mal olan en gelişmiş fiyat özelleştirme planlarına (getiri yönetimi yaklaşımlarının bir parçası) sahiptir. Oldukça başarılı oldular çünkü bu planlar daha yüksek yük faktörlerine ve öncekinden daha fazla gelirlere yol açtı. Diğer endüstriler daha yeni takip etti.

Tabii ki teknoloji, bu konuda özellikle web işletmeleriyle ilgili olarak çok yardımcı oldu. İnternet tabanlı işletmeler genellikle mevcut kuruluşlar için yeni fiyatlandırma baskıları yaratıyor olarak görülürken, Priceline.com'un iş modelinin birçok yönü aslında havayolları için caziptir. Örneğin, çevrimiçi şirket, daha önce satılmayan koltuklar için ek gelir elde edebilecekleri bir aracı oluşturur. Dahası, Priceline.com üzerinden yapılan işlemler, daha ucuz biletlere bir dizi ciddi kısıtlama eklendiğinden, ödeme istekliliği yüksek olan alıcıları etkilemez. Seyahat edenler bir havayolu şirketi belirleyemezler ve kalkış saatleri ve aktarmalar açısından esnek olmaları gerekir. Bununla birlikte, Priceline.com'un başarısının temel nedeni, havayolu ile müşteri arasındaki işlemi özel bir konu olarak tutma becerisidir. Şirket, internetin artan müşteri şeffaflığı üzerindeki zararlı etkilerini etkili bir şekilde sınırlandırıyor. Bu engelin

ortadan kaldırılması, gelecekte çok sayıda yeni fiyat özelleştirme planına ilham vermesi muhtemeldir.

2.3.5.Koşul 5: Algılanan Adalet Kavramları İhlal Edilmemelidir

Bir özelleştirme programının çalışması için bulunması gereken beşinci koşul, bir alıcının bir satıcıyla iş yaparken algıladığı adaletle ilgilidir. Algılanan adalet, alıcının bir işlemde her iki tarafın da kazanç sağladığını hissetmesidir. Kullanılmış bir araba satın alma sürecinde alıcılar, eğitilmiş bir yargıya varmak için arabanın geçmişi hakkında önemli bilgilerden yoksun oldukları için çoğu kez adaletsizliği algırlarlar. Algılanan adalet 'yeni' ekonomide daha önemli bir konu haline geldi ve yöneticiler risklere dikkat etmezlerse özelleştirilmiş fiyatlandırma programlarını tehlikeye atacaklar. Üstelik başarı için gerekli bir koşuldur. Diğer dört koşul yerine getirilmiş olsa bile, adalet algısı yoksa program mahkûm olacaktır. Çoğu, bir mal veya hizmet arzının sınırlı olup olmamasına bağlı olacaktır. Örneğin, belirli bir havayolundaki koltuk kesinlikle dayanıksız bir öğedir ve bu nedenle tedariki sınırlıdır. Uçağın yalnızca x sayıda koltuğu vardır ve bu koltuklar satıldığında veya uçak kalktığında, bu koltuklar sonsuza kadar kullanılamaz. Aksine, belirli bir dağ bisikleti veya paketlenmiş bir market ürünü çok daha fazla arz içindedir. Dağıtım darboğazları ve üretim kesintilerine bakılmaksızın, bu mallar en azından teorik olarak sınırsız olarak temin edilebilir.

Ödeme istekliliğine dayalı bir fiyat özelleştirme planının uygulanması, bir ürünün tedariki sınırlı olduğunda olduğundan çok daha uygun hale gelir. Havayolu fiyatlandırması durumunu hatırlayın (otel odalarında ve kiralık arabalarda da giderek aynı şey oluyor). Yolcular, komşu koltukta oturan yolcuların ödedikleri ücretin yarısını veya belki de iki katını ödemiş olabileceklerini kabul etmeye başladılar. Bir pazarlık yapıldığında herkes mutlu hisseder, ancak fiyat yüksek görünüyorsa genellikle havayoluna kin beslenmez. Bir uçaktaki münferit koltukların fiyatlarının çeşitli koşullar altında satıldığı kabul edilir- 21 gün önceden iptal cezası ile rezerve edilen bir bilet 400 \$ tutabilirken, aynı uçuş için yedi gün önceden satın alınan başka bir bilet iptal cezası olmadığı halde üç kat daha pahalı olabilir. Bir tüketicinin fiyat farklılıklarını atfettiği ve sonuç olarak fiyatı adil olarak algıladığı şey bu kısıtlamalardır.

Aksine, Amazon.com'un tüketicilere tam olarak aynı DVD için nasıl farklı fiyatlar uyguladığı düşünülebilir. Fiziksel ürün, hava yolu koltuğu ile aynıdır. Ancak, DVD tedariki sınırsızdır ve müşterinin gözündeki farkı yaratan da budur. Amazon'un farklı fiyatlarla sattığı bilgisi,

kızgınlığa ve şirketin tüketicinin pahasına kâr sağladığını hissine neden oluyor. Amazon'un kar marjının ayrıntılarını bilmeseler de, Amazon'un bir DVD grubu için ödediği fiyatın çok fazla değişmediğinden oldukça emin olabilirler. Amazon'un davasında şirketin tüketici şampiyonu imajı nedeniyle ihanet duyguları abartılabilir. Aynı DVD için farklı fiyatlar uygulama uygulaması öğrenildiğinde, Amazon ürünlerinin alıcılarının kızması şaşırtıcı değildir.

Bir ürünün tedarikinin bol olduğu durumlarda bile, farklı fiyatlandırmanın olumsuz yanından kaçınmanın yolları vardır. Elbette temel bir gereklilik, müşteri ile firma arasındaki işlemi özel bir konu olarak tutmaktır. Catalina Marketing, bir müşteri için indirimlerin diğer alıcılar tarafından tamamen bilinmemesini sağlar. Aynı şekilde, müşterilerin biletleri için ne kadar ödeme yaptığını yalnızca Priceline.com ve havayolu şirketi bilir. Teoride Amazon'un işlemleri yalnızca belirli alışveriş yapanlar ve şirket tarafından biliniyor, ancak yine de muhtemelen öfkeli alışverişçilerin tutarsızlığa dikkat çekmesi ve fikirlerini çevrimiçi olarak ifade etmelerinin bir sonucu olarak halka açıldı. Çoğu büyük tüketim malları şirketi, haklarından mahrum müşteriler tarafından hazırlanan en az bir web sitesinden bu tür geri bildirim alır (ör. Starbucked.com ve Walmartsurvivor.com). Fiyat özelleştirme planlarına başlamak üzere olan şirketler, pazarlamadaki asırlık atasözünün bilhassa bilincinde olmalıdır: ilişkiler zaman içinde kurulur, ancak tek bir işlemle yok edilebilirler.

İkinci bir strateji, kitapçı Barnes & Noble Inc.'in çevrimiçi yan kuruluşu olan BN.com tarafından çevrimdışı ve çevrimiçi işlemlerin ayrılmasıdır.

Artan şeffaflığa üçüncü bir yanıt, aynı temel ürün üzerinde varyasyonların uygulanmasını içeren ürün 'versiyonlama'ya girişmektir (Shapiro ve Varian, 1998). QXL veya Ebay gibi çevrimiçi müzayedeler, insanların farklı ödeme istekliliklerinden para kazanarak başarılı olan fiyat özelleştiricilerinden biraz daha fazlasıdır. Algılanan adalet burada çok daha az sorun teşkil ediyor çünkü neredeyse hiçbir satın alma (örneğin ikinci el bir çamaşır makinesi) olduğu gibi çoğaltılamıyor. Dolayısıyla değişen fiyatları gerekçelendirmek mümkündür. Dördüncü yaklaşım, ürünün bulunabilirliğine bir zaman sınırı koymak veya onu 'dayanaksız' hale getirmektir. Bu koşullarda ayrımcı fiyatlandırma seyahat endüstrisi tarafından on yıllardır uygulanıyor, ancak diğer sektörlerde potansiyel olarak mümkündür (Reinhartz, 2002).

2.4.DİNAMİK FİYATLANDIRMADA KULLANILAN MODELLER

Dinamik fiyatların hesaplanmasında çeşitli matematiksel modeller kullanılmıştır. Bu modellerin çoğu dinamik fiyatlandırma problemini bir optimizasyon problemi olarak formüle etmektedir. Kullanılan ve vurgulanan belirli matematiksel araca bağlı olarak, beş model kategorisi aşağıda listelenmiştir.

- Envantere dayalı modeller: Bunlar, fiyatlandırma kararlarının öncelikle envanter düzeylerine ve müşteri hizmet düzeylerine dayalı olduğu modellerdir.
- Veriye dayalı modeller: Bu modeller, optimum dinamik fiyatları hesaplamak için müşteri tercihleri ve satın alma modelleri hakkında mevcut verileri kullanmak için istatistiksel veya benzer teknikleri kullanır.
- Oyun teorisi modelleri: Çok satıcılı bir senaryoda, satıcılar aynı müşteri havuzu için rekabet edebilir ve bu da satıcılar arasında dinamik bir fiyatlandırma oyununa neden olur. Oyun teorik modelleri, bu gibi durumlarda optimal dinamik fiyatları hesaplamanın ilginç yollarına yol açar.
- Makine öğrenimi modelleri: Bir e-iş pazarı, alıcılar ve satıcılar tarafından çevrimiçi öğrenme için zengin bir oyun alanı sağlar. Satıcılar potansiyel olarak alıcı tercihlerini ve satın alma modellerini öğrenebilir ve gelirleri veya karları en üst düzeye çıkarmak için tekliflerini dinamik olarak fiyatlandırmak için algoritmalar kullanabilir.
- Simülasyon modelleri: Simülasyonun her zaman herhangi bir karar verme probleminde kullanılabileceği iyi bilinmektedir. Dinamik fiyatlandırma için bir simülasyon modeli, yukarıda belirtilen dört modelden herhangi birini kullanabilir veya bir prototip sistemi veya sistemin dinamiklerini taklit etmenin başka bir yolunu kullanabilir.

Dinamik fiyatlandırma modellerini kategorize etmenin yukarıdaki yolu hiçbir şekilde kesin bir yol değildir. Kategorizasyon ne birbirini dışlayan ne de müştereken kapsamlıdır. Belirli bir dinamik fiyatlandırma şeması, yukarıdaki türlerden iki veya daha fazlasını içerebilir. Belirli bir model tipi başka bir tip kullanabilir. Örneğin, envantere dayalı modeller veriye dayalı olabilir. Makine öğrenimi modelleri veri odaklı olabilir. Makine öğrenimi modelleri, öğrenme algoritmalarında vb. envanter seviyelerini kullanabilir. Simülasyon, diğer tüm model türleri için geçerlidir.

2.4.1. Envantere Dayalı Modeller

Elmaghraby ve Keskinocak (2003), bir perakendecinin karşılaştığı dinamik fiyatlandırma probleminin türünü etkileyen bir pazar ortamının üç ana özelliğini tartışmaktadır:

- Envanterin yenilenmesine karşı envanterin yenilenmemesi (R/NR): Belirli bir zaman diliminde, satıcının sabit bir envanter miktarı veriliyken fiyatlandırma kararları mı alacağı yoksa envanter, talebi karşılamak için zamanla yenilenebilir.
- Zaman içinde bağımlı ve bağımsız Talep: Müşterilerin bir ürüne yönelik talebi zaman içinde değişebilir.
- Miyop ve stratejik müşteriler (M/S): Müşterilerin satın alma davranışı, zaman içinde satıcının kararını etkiler. Miyop müşteriler, fiyat değerinin altındaysa satın alma yaparlar. Stratejik müşteriler, satın alma kararları verirken fiyatların gelecekteki yolunu dikkate alır

Mevcut pazarların çoğu üç kategori altında sınıflandırılabilir:

NRIM (envanterden bağımsız taleplerin yenilenmesi yok-miyop müşteriler), NRIS (envanterin yenilenmemesi-bağımsız talepler-stratejik müşteriler) ve RIM (envanterden bağımsız taleplerin yenilenmesi-miyop müşteriler). NRIM örnekleri, moda giyim veya tatil ürünlerini içerirken, RIM durumu bakkal ürünlerinde, ürünlerde ve farmasötik ürünlerde görülür. NRIS kategorisi, tipik bir işletmeden işletmeye satın almadır.

Gallego ve van Ryzin [21], sonlu ufukta stokastik talebe sahip stokların optimal dinamik fiyatlandırmasını ele alıyor. Burada yapılan varsayımlar şunlardır:

1. Piyasa tekeli bir piyasadır,
2. Satış ufku sonludur,
3. Mağazanın satış ufku boyunca ikmali olmayan sonlu bir ürün stoğu vardır,
4. Pazarda fiyat arttıkça talep azalır,
5. Satılmayan öğelerin bir kurtarma değeri vardır.

Gallego ve van Ryzin (1994) talebi, $\lambda(p)$ 'nin p 'de arttığı $\lambda(p)$ yoğunluğuna sahip bir Poisson süreci olarak modeller. t zamanında p_t fiyatını yükleyerek, firma talebin yoğunluğunu kontrol eder. Uygun varsayımlar altında şunları gösterirler: (a) daha fazla stok ve/veya mal satmak için daha uzun kalan süre, daha yüksek beklenen gelirlere yol açar; (b) belirli bir zamanda, envanter arttıkça optimal fiyat düşer- tersine, belirli bir envanter seviyesi için, satmak için daha fazla zaman varsa optimal fiyat yükselir. Türetilen optimal fiyatlandırma politikaları, fiyatların zaman içinde sürekli güncellenmesini gerektirir ve bu her zaman pratik olmayabilir.

Yazarlar, daha istikrarlı fiyatlarla buluşsal fiyatlandırma politikalarını araştırmıştır. Ayrıca fiyatların ayrı bir dizi izin verilen fiyattan seçilmesi gerektiği duruma da bakmaktadırlar.

Federgruen ve Heching (1999), fiyatların zaman içinde periyodik olarak değiştiği belirsiz bir taleple karşı karşıya kalan bir satıcının optimal envanter ve fiyatlandırma politikasını ele almaktadır. Her periyotta, talep gerçekleşmeden önce, satıcı, başlangıç stok pozisyonu x_t verildiğinde üretilecek miktara (q_t) karar vermelidir, burada t kalan dönem sayısını gösterir. Benzer şekilde, satıcı, dönem başında elinde ne kadar stok bulunacağına karar verir. Bir baz stok liste fiyatı (BSLP) politikasının geniş bir ayar aralığı altında optimal olduğu bulunmuştur. Bir BSLP politikası şu şekilde tanımlanır:

a) t , x_t döneminin başlangıcındaki stok, b_t baz stok seviyesinden azsa, stok seviyesini b_t 'ye ve ücret p_t 'ye getirmeye yetecek kadar üretir,

b) x_t , b_t 'den büyükse, hiçbir şey üretmeyin ve ürünü $p_t(x_t)$ 'nin sayılan fiyatından teklif edin, burada p_t , x_t 'nin azalan bir fonksiyonudur. Zaman ufku sonsuz olduğunda, yazarlar iki farklı hedefi göz önünde bulundururlar. Satıcı, beklenen indirimli karı maksimize etmek istediğinde, BSLP'nin optimal olduğunu bulur. Satıcı, ortalama uzun vadeli karı maksimize etmek isterse, fiyatların serbestçe hareket etmesine izin verilirse, optimal fiyatlandırma politikası bir BSLP politikası olacaktır.

Bernstein ve Federgruen (2005), rastgele taleplere sahip iki kademeli bir tedarik zincirinde envantere dayalı fiyatlandırmayı ele almaktadır.

Öğrenme Eğrisi Simülatörü, sonlu zaman dilimleri ve dalgalanan alıcı talepleri altındaki piyasalarda envanter tabanlı dinamik fiyatlandırma stratejilerini analiz etmek için MIT Medya Laboratuvarlarında tasarlanmış ve uygulanmış bir piyasa simülatörüdür. Sonlu pazarları, yani

sınırlı bir zaman ufku, sınırlı satıcı envanterleri ve sınırlı alıcı nüfusu olan pazarları simüle edebilir. Çok çeşitli alıcı davranışlarını ve çok çeşitli satıcı stratejilerini modelleyebilir. Bu simülatörü kullanarak, (DiMicco ve diğ. 2003) tek bir satıcı pazarında birkaç envanter tabanlı dinamik fiyatlandırma stratejilerini karşılaştırır.

Biller ve diğ. (2005), gelir ve arzı iyileştirmek için otomotiv endüstrisinde dinamik fiyatlandırma, doğrudan müşteri modeli, üretim planlaması ve üretim kapasitesi sınırları altında envanter kontrolünü içeren bir strateji önermektedir. Dinamik fiyatlandırma problemini, envanter kısıtlamaları ve üretim kapasitesi kısıtlamalarına bağlı olarak toplam gelir eksi elde tutma maliyetleri ve üretim maliyetlerini maksimize eden bir optimizasyon problemi olarak formüle ederler. Sorun, dışbükey maliyetle minimum maliyetli bir ağ akış sorunu olarak ortaya çıkıyor. Analizleri, dinamik fiyatlandırma ile önemli bir gelir artışı elde etmenin mümkün olduğunu gösteriyor.

2.4.2. Veriye Dayalı Modeller

E-ticaret web siteleri aracılığıyla müşteri verilerinin mevcudiyeti, gelir artırıcı önlemler için muazzam fırsatlar açmıştır. Amazon.com, yahoo.com gibi e-ticaret siteleri ve tüm önde gelen üretim ve hizmet şirketlerinin özel pazar yerleri, müşteriler hakkında gelirlerini ve karlarını artırmak için kullanabilecekleri çok büyük miktarda veri toplar. Aslında, müşteri verilerinden en iyi şekilde yararlanmak için karmaşık veri madenciliği algoritmaları geliştirilmektedir. Dinamik fiyatlandırma, müşteri verilerinin ve veri madenciliği algoritmalarının kullanılabilirliğinden önemli ölçüde etkilenen alanlardan biridir.

Dinamik fiyatlandırma için veri odaklı yaklaşımına ilk örnek, geleneksel olarak müşteri verileri tarafından yönlendirilen gelir veya getiri yönetimidir. Havayolları ve konaklama endüstrisi bu teknikleri oldukça başarılı bir şekilde benimsemiştir.

Boyd ve Bilegan (2003), merkezi rezervasyon ve gelir optimizasyon sistemleri tarafından etkinleştirilen dinamik, otomatikleştirilmiş satışların başarılı bir e-ticaret modelini göstermek için gelir yönetimi tekniklerini araştırmıştır. Morris ve diğ. (2000), müşteri tercihlerindeki kalıpları keşfederek havayolları endüstrisindeki dinamik fiyatlandırma stratejilerini incelemiştir. İki uyarlanabilir satıcı tarafı fiyatlandırma stratejisi, Java tabanlı bir pazar simülatörü olan Arena kullanılarak sunulmuş ve değerlendirilmiştir. Simülatör kullanılarak, rezerv fiyatlandırma stratejisi ve koltuk serbest bırakma stratejisi, artan, azalan ve sabit müşteri

talepleri olmak üzere üç koşulda temel durum ile karşılaştırılmıştır. Sonuçlar, simülasyonda o ana kadar satılan koltuk sayısına göre rezerv fiyatını ayarlayarak, rezerv fiyatlandırma stratejisinin doğasını takip eden türevin talebi çok iyi takip edebildiğini ve baz duruma göre geliri artırdığını ortaya koymuştur. Buna karşılık, talep düzeyine göre tahsis edilen koltuk sayısını ayarlamaya yönelik miyop olarak optimal bir strateji, havayolu ihalesi senaryosunda geliri artırmayı başaramamıştır. Bu stratejilerin her ikisinin veya yeni icat edilmiş stratejilerin bir kombinasyonu, dalgalanan müşteri ile simüle edilmiştir. Bu stratejilerin her ikisinin veya yeni icat edilmiş stratejilerin bir kombinasyonu hem yedek fiyatta hem de günlük serbest bırakılan koltuk sayısında daha ince ayar yapmak ve gelir üretimini optimize etmek için dalgalanan müşteri talep seviyeleri ile simüle edildi.

Ford motor şirketi, tüketicilerin bir prim ödemeye hazır oldukları ürün özelliklerini belirleyerek, tüketicileri daha pahalı araçlar satın almaya teşvik eden bir fiyatlandırma stratejisi geliştirerek gelir ve kârda belirgin bir artışa neden oldu (Coy, 2000).

Rusmevichientong ve diğ. (2005) General Motors tarafından geliştirilen Auto Choice Adviser web sitesi aracılığıyla toplanan tüketici tercihlerine ilişkin çevrimiçi verileri kullanan optimal dinamik fiyatları belirlemek için parametrik olmayan, veriye dayalı bir yaklaşım geliştirmişlerdir. Yazarlar, web sitesinde bulunan verileri kullanarak bir gelir optimizasyon problemi formüle ederler. Sorunun NP-zor olduğu ortaya çıkmıştır. Yazarlar, amaç fonksiyonu süper modüler olduğunda sorunu çözmek için verimli bir buluşsal yöntem geliştirmiştir. General Motors, otomobilleri için geliri maksimize eden dinamik fiyatlar elde etmek için Auto Choice Adviser web sitesinden elde edilen verileri kullanan yukarıdaki modeli kullanmıştır.

Müşteri verileri web siteleri ve müşteri ilişkileri yönetimi yazılımları aracılığıyla elde edildiğinde, daha iyi fiyatlandırma yollarını belirlemek için bu verileri analiz etmek ve kullanmak için çeşitli teknikler kullanılabilir. İstatistiksel/makine öğrenimi teknikleri burada oldukça popülerdir.

2.4.3.Açık Artırmaya Dayalı Modeller

Açık artırmalar, dinamik fiyatlandırma için doğal bir model oluşturur. Bir müzayedenin sonucu, arz-talep özellikleri tarafından belirlenir ve bu nedenle, bir müzayede tarafından belirlenen fiyatlar, teklif sahiplerinin gerçek değerlemelerini açıklamaları koşuluyla, gerçekten piyasa koşullarına dayanabilir. Açık artırma mekanizmaları, gerçeği açığa çıkarma özelliklerine sahip

olacak şekilde tasarlanabilir ve açık artırma teorisinin dinamik fiyatlandırma alanına sunacağı çok şey vardır. Açık artırmalar, yüksek Pareto verimliliği oranlarına ulaşır ve dengeye hızlı yakınsama sergiler. Bu özellikler, büyük şirketlerin gelirlerinin önemli bir kısmı için onlara bağımlı olan tedarikçilerden doğrudan veya dolaylı malzeme satın aldığı bir ortamda çok çekici olacaktır.

Açık artırmalar, B2B durumlarının fiyat müzakerelerini uygulamak için muhtemelen en popüler mekanizmadır. General Electric, satın alma işlemlerinin çoğu için çevrimiçi açık artırmaları benimsemiş ve 2000 yılında 6 milyardan fazla çevrimiçi açık artırma gerçekleştirmiştir ve bu, İnternet Haftası dergisinin “2000 Yılı'nın e-İşi” unvanını vermesine yol açmıştır. Çok sayıda büyük şirket, satın alma/satış operasyonları için açık artırmaya dayalı yöntemler veya internet tabanlı otomatik müzakereleri kullanmış veya kullanma sürecindedir. E-ihalelerin satın almada ve satışta başarılı bir şekilde uygulanmasına ilişkin yayınlanmış birçok vaka çalışması bulunmaktadır.

Açık artırmalar, ebay açık artırmaları, yahoo açık artırmaları, amazon açık artırmaları ve uçak biletleri, kullanılmış arabalar, eğlence kuponları, otel rezervasyonları vb. için sayısız açık artırma sitelerinin başarısı ile gösterildiği gibi B2C durumlarında da en popüler dinamik fiyatlandırma mekanizmalardandır.

Açık artırmalar çeşitli biçimlerde olabilir ve her bir açık artırma mekanizması türü, belirli bir fiyatlandırma sonucunu uygular. Bichler ve diğerleri (2002), e-satın alma, e-satış, teklif hazırlama, tersine lojistik, vb. bağlamında dinamik fiyatlandırmada açık artırmaların rolünü ayrıntılı olarak açıklamıştır. Narahari ve Dayama (2005), e-iş durumlarında kullanılan önemli bir açık artırma mekanizmaları sınıfını temsil eden birleştirici açık artırmalara bakmaktadır. Elmaghraby'nin (2005) makalesi, e-pazaryerlerinde açık artırmalar ve fiyatlandırma üzerine odaklanmış bir araştırmadır.

2.4.4.Oyun Teorik Modelleri

Oyun teorik modelleri, rasyonel ve bencil ajanların etkileşiminde ortaya çıkan çatışma ve iş birliği durumlarının modellenmesinde kullanılacak doğal bir araç sağlar. Birden fazla rakip satıcıdan oluşan bir piyasa kurumunda oyun teorisi uygun bir modelleme aracı sağlar. Aslında, oyun teorisi elektronik pazarların tasarımı için temel sağlar (Kalagnanam ve Parkes, 2005).

Hem işbirlikçi olmayan oyun teorisi hem de işbirlikçi oyun teorisi, e-iş pazarlarında dinamik fiyatlandırma problemini modellemek için uygundur.

E-iş pazarlarında dinamik fiyatlandırma için oyun teorik yaklaşımını kullanmaya yönelik birkaç çalışma vardır. Örneğin, Bernstein ve Federgruen (2003, 2005), bir tedarikçinin talep belirsizliği altında rekabet eden perakendeciler ağına hizmet verdiği iki kademeli bir tedarik zincirindeki dinamik fiyatlandırma problemini ele almaktadır. Bernstein ve Federgruen (2005)'de tek bir periyot modeli ve Bernstein ve Federgruen (2003)'de periyodik bir gözden geçirme modeli varsayarlar ve her iki durumda da sonsuz bir ufuk problemini incelerler. Bernstein ve Federgruen (2003)'de, her dönemde bir perakendeci, dağıtımı kendi perakende fiyatına ve diğer perakendeciler tarafından talep edilen fiyatlara bağlı olan rastgele bir taleple karşı karşıyadır. Modelin iki versiyonu düşünülmüştür. İlk modelde, her perakendeci, bekleyen siparişlerde birikme maliyetlerine maruz kalır. İkinci modelde, uygun envanter seviyeleri, bireysel perakendecilerin hizmet seviyesi kısıtlamaları tarafından tetiklenir. Tedarikçinin birim toptan satış fiyatı başına sabit bir ücret talep ettiğini varsayarsak, modelin rakip perakendeciler arasında işbirlikçi olmayan bir oyunu teşvik ettiği gösterilmiştir. Bu oyunun Nash dengesi altında, her perakendecinin sabit bir perakende fiyatı ve sabit bir baz stok seviyesi ile bir baz stok politikası benimsediği gösterilmiştir. Ayrıca, belirli bir sabit toptan satış fiyatları seti altında, tedarikçi ve perakendecilerin sistem genelindeki toplam uzun vadeli karlarının, tamamen merkezi bir sistemde elde edilebilecek kadar büyük olduğu da gösterilmiştir.

Oyun teorik modelleri son zamanlarda ağ/internet kaynaklarının fiyatlandırılması alanında kullanılmaktadır (Cao ve diğ., 2002). Ağ ayarlarında, dinamik fiyatlandırma, maliyeti geri kazanma, farklı hizmet sağlayıcılar arasındaki rekabeti artırma, tıkanıklığı azaltma ve trafik yoğunluğunu kontrol etme konusunda etkili bir araç olarak kullanılabilir. Oyun teorik modelleri alakalı hale gelir çünkü bir ağdaki varlıklar bencildir ve etkileşimleri işbirlikçi olmayan veya işbirlikçi bir oyun olarak modellenebilir. Cao ve diğ. (2002) makalelerinde, İnternet fiyatlandırma problemini modellemede lider-takipçi oyunları, işbirlikçi oyunlar ve iki kişilik sıfır olmayan toplamli oyunların kullanımını incelemektedir. İşbirlikçi oyunlara dayalı modellerin, İnternet fiyatlandırma problemini modellemenin en gerçekçi yolunu sağladığı gösterilmiştir. İnternet fiyatlandırması ve ağ fiyatlandırması bağlamında kullanılan oyun teorik modelleri, e-iş bağamlarına oldukça basit bir şekilde uygulanabilir.

2.4.5.Makine Öğrenimi Tabanlı Modeller

Makine öğrenimi, son zamanlarda e-ticarette dinamik fiyatlandırma için popüler bir modelleme aracı olarak ortaya çıktı. Tipik bir pazarda, ortam sürekli olarak değişen talepler ve arzlarla birlikte değişir. Böyle bir senaryoda, sistemin olası tüm evrimlerini öngörmek imkansızdır. Mevcut bilgi miktarı da sınırlıdır (örneğin, bir satıcı, rakip satıcıların fiyatları hakkında tam bilgiye sahip değildir). Öğrenmeye dayalı modellerle, mevcut tüm verileri perspektife sokabilir ve çevreye en iyi şekilde uyum sağlamak için fiyatlandırma stratejisini değiştirebilir. Dinamik fiyatlandırmaya yönelik veri sürücüsü yaklaşımları, dinamik fiyatları belirlemek için makine öğrenimi tekniklerini kullanabilir.

Dinamik fiyatlandırmaya bu yaklaşımla ilgili oldukça fazla literatür mevcuttur. Bu literatür mantıksal tekli öğrenme aracı modelleri ve çoklu öğrenme aracı modelleri olarak sınıflandırılabilir.

2.4.5.1.Tek Bir Öğrenme Aracılı Modeller

Brooks ve diğ. (1999), iki farklı fiyatlandırma stratejisinin (her ikisi de makine öğrenimine dayalı) performansı, elektronik ürünler için tek satıcı pazarları bağlamında karşılaştırılmıştır. İlk strateji tek parametrelili fiyatlandırma modeli kullanır ve ikincisi iki parametrelili fiyatlandırma modeli kullanır. İki parametrelili öğrenmeye dayalı dinamik bir fiyatlandırma stratejisinin, tek parametrelili öğrenmeye dayalı olandan açıkça daha iyi performans gösterdiği gösterilmiştir. Makale, kısmi bilgi içeren bir model için optimal fiyatları belirlemeye yönelik analitik yöntemler türetmektedir. Simülasyonlar, satıcının müşteri değerlemelerinden emin olmadığı ve optimal fiyatları kademeli olarak öğrendiği dinamik bir modeli keşfetmek için kullanılır.

Gupta ve diğ. (2002), teklif sahiplerinin geliş şekli ve bireysel fiyat-talep eğrileri ile ilgili belirsizliğin var olduğu durumlarda, müzayedecinin kalemlerin birim fiyatını kademeli olarak azalttığı ve toplam beklenen geliri en üst düzeye çıkarmak için azalan bir fiyat dizisi bulma problemini modellediği web tabanlı çok birimli bir Hollanda müzayedesini ele almıştır. Yukarıdaki karar problemi, belirsiz bir durağan olmayan müzayede ortamında tek bir aracı RL olarak modellenmiştir. Bağımsız teklif veren değerlemelerinin varsayımı altında, yazarlar, indirimsiz getirileri olan bir sonlu ufuk Markov karar süreci modeli geliştirmiş ve bunu bir Q-öğrenme algoritması kullanarak çözmüştür.

Carvalho ve Puterman (2003), bir T süresi boyunca beklenen toplam geliri optimize etmek için bir malın fiyatını belirlemesi gereken bir perakendeci problemini ele alır. Talep fonksiyonu bilindiğinde, durum basit bir stokastik maksimizasyon problemine indirgenir. Bununla birlikte, talep fonksiyonu bilinmediğinde, perakendeci, fiyatlandırma kararlarını yönlendirmek için belirsiz ön bilgilere güvenmek zorundadır. Bu yazıda, parametreleri bilinmeyen bir parametrik model ele alınmıştır. Örneğin, satıştan t gün sonra, satıcı önceki $t-1$ gün için belirlediği fiyatları bilir ve önceki $t-1$ gündeki talepleri gözlemleyebilir. Model, talebin logaritmasının fiyatın doğrusal bir fonksiyonu olduğu basit bir log-lineer regresyon modelidir. Satıcı, talep fonksiyonunun parametreleri hakkında bilgi edinebilir ve belirli bir zaman ufku boyunca gelirleri maksimize edecek şekilde fiyatları belirlemek için kullanabilir. Çeşitli fiyatlandırma kuralları incelenir ve karşılaştırılır. Tek adımlı ileriye bakma kuralının, incelenen tek bir satıcı ortamı için oldukça sağlam bir şekilde çalıştığı gösterilmiştir.

Leloup ve Deveau (2001), bir web mağazasını düşünmüş ve web mağazasının fiyatlandırma problemini eşleştirmek için Rothschild (1974)'in dinamik fiyatlandırma modelini uygulamıştır. Simülasyonları kullanarak, belirli bir pazardaki tüm satıcılar optimal bir fiyatlandırma politikası izlediğinde ortaya çıkabilecek fiyat dinamiklerini incelerler.

Raju ve diğ. (2003, 2004, 2004, 2005), tek satıcılı (rekabetsiz) elektronik perakende pazarlarına incelemiştir. Satıcının, standart bir envanter politikasına göre doldurduğu bir ürün envanteri vardır. Satıcı, sistemdeki öğrenme aracıdır ve çevreden öğrenmek için pekiştirmeli öğrenmeyi kullanır. Sorun, satıcının performans ölçütünü (uzun vadeli iskonto edilmiş kâr veya birim zaman başına uzun vadeli ortalama kâr) optimize eden dinamik fiyatları belirlemektir. Müşterilerin varış süreci, müşterilerin değerlemeleri, stok yenileme politikası ve stok yenileme teslim süresi dağılımı ile ilgili (makul) varsayımlar altında sistem bir Markov karar süreci haline gelerek RL algoritmalarının kullanımına olanak sağlar. Problemi çözmek için RL için Q-öğrenme algoritması kullanılır. Model ve çözüm metodolojisi, takip edilen envanter politikası için optimal yeniden sipariş miktarını ve optimal yeniden sipariş noktasını hesaplamak için de kullanılabilir. Bu araştırma iki ayrı, temsili durum için gerçekleştirilir:

- Ürünün farklı miktarlarına doğrusal olmayan fiyatların sunulduğu bir perakende pazarı (Raju ve diğ., 2004).
- Tutsaklar ve alışveriş yapanlar olmak üzere iki doğal müşteri segmentinin bulunduğu bir perakende pazarı (Raju ve diğ., 2003, 2006a). Tutsaklar olgun, sadık alıcılardır,

alışveriş yapanlar ise fiyata daha duyarlıdır ve satış promosyonları ve toplu indirimlerden etkilenir.

2.4.5.2. *Birden Çok Öğrenme Aracılı Modeller*

Ravikumar ve diğ. (2002), bilgili ve bilgisiz iki çeşit alıcı akışına hizmet vermek için rekabet eden iki satıcı ile bir hizmet piyasası ortamını incelemiştir. Her iki satıcının da RL tabanlı uyarlanabilir bir davranış izlediğini varsayılmış ve sistemi genel toplam Markovian oyunu olarak modellimışlerdir. Aktör-eleştirmen tipi bir RL şeması önerirler ve yakınsama üzerine deneysel sonuçlar sağlamışlardır.

Hu ve Zhang (2002), simüle edilmiş bir piyasada üç farklı türde fiyatlandırma algoritması (veya fiyatlandırma araçları) üzerinde çalışmıştır. İlk temsilci, o eylem için aldığı ödüllere dayalı olarak bir dönem için en uygun eylemi öğrenerek fiyatları belirlemek için pekiştirmeli öğrenmeyi kullanmıştır. İkinci ajan, ajanın kendi eylemleri için uzun vadeli optimal değerleri temsil eden Q değerlerini öğrenerek geleneksel bir Q-öğrenme yöntemini kullanmıştır. Üçüncü ajan, ajanın ortak eylemleri için uzun vadeli Nash denge değerlerini temsil eden Q değerlerini öğrenerek sofistike bir Nash Qlearning algoritması kullanmıştır. Üçüncü ajan, ikinci ajandan daha iyi performans gösterir ve ikinci ajan, ajanların birbirleriyle rekabet ettiği simüle edilmiş bir piyasada birinci ajandan daha iyi performans göstermiştir. Bu, gelecekteki ödülleri hesaba katan öğrenme yöntemlerinin miyop yöntemlerden daha iyi performans gösterdiğini göstermektedir. Ayrıca, diğer etmenlerin varlığını hesaba katan öğrenme yöntemi, diğer etmenleri yok sayan yöntemden daha iyi performans gösterir.

Greenwald ve diğ. (1999), her satıcının bir fiyat belirleme stratejisi kullanan bir fiyat robotu kullandığı çok satıcılı bir ortamda stratejik fiyat robotu dinamiklerini anlamaya çalışmıştır. Dört farklı fiyat belirleme stratejisini incelerler: oyun teorik fiyatlandırması, en uygun fiyatlandırma, türev takibi ve bilgi ve hesaplama gereksinimlerinde farklılık gösteren Q-öğrenme. Homojen ortamlarda, tüm fiyat robotları aynı fiyatlandırma algoritmasını kullandığında, türev izleme yaklaşımının oyun teorik fiyatlandırmasından ve en uygun olmayan fiyatlandırmadan daha iyi performans gösterdiği gösterilmiştir. Heterojen fiyat robotlarının olduğu bir pazarda, optimal olmayan ve oyun teorik fiyatlandırması, türev takipten daha iyi performans gösterirken, Q-öğrenme stratejisi diğerlerinden daha iyi performans göstermiştir.

Kephart ve Tesauro (2000), iki özdeş, rekabet eden fiyat robotunun bir metayı stratejik olarak fiyatlandırıdığı bir model pazarda çok etmenli Q-öğrenmenin özelliklerini incelemiştir. Temelde farklı iki çözüm gözlemlendi: simetrik politikalardan oluşan sıfır Bellman hatası olan kesin, durağan bir çözüm ve küçük ama sıfır olmayan Bellman hatası olan durağan olmayan, kırık simetrik bir sözde çözüm. Bu sözde yakınsak asimetrik çözümün sıradan Q-öğrenmede analogu yoktur. Yazarlar her iki çözümün formunu analitik olarak hesaplar ve her birinin meydana geldiği koşulları sayısal olarak haritalar. Bu gözlemlenen davranışın, çok etmenli Q-öğrenme ile ilgili diğer çalışmalarda daha genel olarak bulunacağı ileri sürülmektedir.

Dasgupta ve Das (2000), birden çok satıcı ve birden çok alıcıdan oluşan çok etmenli bir ekonomide fiyat dinamiklerini incelemiştir. Alıcılar mağaza robotlarını, satıcılar ise fiyat robotlarını kullanmıştır. Yazarlar, dinamik fiyatlandırma için saf bir türev izleyen algoritmayı geliştiren, öğrenmeye dayalı bir model optimize edici algoritma ile gelmişlerdir. Simülasyonu kullanarak, model optimize edici algoritmasının kullanımının, piyasa hakkında herhangi bir ek bilgiye sahip olmamasına rağmen, performansı önemli ölçüde iyileştirdiğini göstermektedir. Bu, makine öğreniminin rekabeti veya iş birliğini teşvik etmede ve gelir maksimizasyonunda etkili bir rolü olduğunu gösteriyor.

Raju ve diğ., (2006b), birden fazla satıcının gelen alıcıları çekmek için fiyat üzerinde rekabet ettiği bir elektronik perakende pazarını düşünüyor. Ele alınan pazarlarda, satıcılar otomatik fiyatlandırma araçları veya fiyat robotları kullanır. Bir fiyat robotu, indirimli kümülatif karı veya birim zaman başına uzun vadeli ortalama karı maksimize etmek amacıyla zaman, talep bilgisi ve arz mevcudiyeti gibi faktörlere dayalı olarak satıcısının fiyatını rastgele aralıklarla sıfırlar. İki durum incelenir:

Durum 1: Burada hiçbir satıcı, diğer satıcıların durumlarından ve fiyatlarından haberdar değildir. Q-öğrenme algoritması, seçkin bir satıcının fiyat robotu için kullanılır ve performansı, iyi bilinen türev izleme (DF) stratejisi gibi diğer uyarlanabilir teknikleri kullanan fiyat robotlarının performansı ile karşılaştırılır.

Durum 2: Her satıcı, diğer satıcıların durumları ve fiyatları hakkında bilgi sahibidir. Burada iki satıcılı dinamik fiyatlandırma problemi bir Markovian oyunu olarak modellenmiştir ve problem RL çerçevesinde formüle edilmiştir.

Makine öğrenimi, satıcı araçları tarafından, sonuçları bilinen bir teklif işlemleri veri tabanından kazanma olasılığını doğrudan öğrenmek için kullanılır. Dinamik fiyatlandırma stratejilerini belirlemede farklı öğrenme biçimlerini kullanan birkaç başka makale var. Bunlar, İnternet fiyatlandırması için bir kuyruğa alma teorik ortamında öğrenmenin kullanımını içerir (Dube ve diğ., 2002).

2.5.MAKİNE ÖĞRENMESİ

2.5.1. Neden Makine Öğrenmesi

Neredeyse sınırsız miktarda mevcut veri, uygun fiyatlı veri depolama ve daha ucuz ve daha güçlü işlemenin büyümesi, makine öğreniminin büyümesini hızlandırmıştır. Artık birçok endüstri, daha büyük ölçeklerde daha hızlı ve daha doğru sonuçlar sunarken daha büyük ve daha karmaşık verileri analiz edebilen daha sağlam makine öğrenimi modelleri geliştirmektedir. Makine öğrenimi araçları, kuruluşların karlı fırsatları ve potansiyel riskleri daha hızlı belirlemesini sağlamaktadır.

Makine öğreniminin pratik uygulamaları, bir şirketin kârlılığını önemli ölçüde etkileyebilecek iş sonuçlarını yönlendirir. Alandaki yeni teknikler hızla gelişmekte ve makine öğrenimi uygulamasını neredeyse sınırsız olanaklara genişletmektedir. Çok büyük miktarda veriye dayanan ve bunları verimli ve doğru bir şekilde analiz etmek için bir sisteme ihtiyaç duyan endüstriler, modeller oluşturmanın, strateji oluşturmanın ve planlamanın en iyi yolu olarak makine öğrenimini benimsemiştir (Quantilus, 2020).

2.5.2.Makine Öğrenmesi Nedir

Makine öğrenimi, makinelere verileri daha verimli bir şekilde nasıl kullanacaklarını öğretmek için kullanılır. Bazen veriler görüntülendikten sonra deseni yorumlanamayabilir veya verilerden bilgi çıkarılamayabilir. Bu durumda, makine öğrenimini uygulanır (Richert ve Coelho, 2015). Mevcut veri kümelerinin bolluğuyla, makine öğrenimine olan talep artmaktadır. Tıptan orduya, ulaşımdan havacılığa kadar pek çok sektör, hedefledikleri bilgilere ulaşmak için makine öğrenimini kullanmaktadır. Makine öğrenimi, laboratuvar merakından başlayıp yaygın ticari kullanımda pratik bir teknolojiye kadar özellikle son yıllarda çarpıcı bir şekilde ilerlemiştir. Yapay zekâ (AI) içinde, makine öğrenimi, bilgisayarla görme, konuşma tanıma,

doğal dil işleme, robot kontrolü ve diğer uygulamalara yönelik olarak pratik yazılım geliştirmek için tercih edilen yöntem olarak ortaya çıkmaktadır.

Birçok yapay zekâ sistemi geliştiricisi, birçok uygulama için, bir sistemi, tüm olası girdiler için istenen yanıtı önceden tahmin ederek manuel olarak programlamaktan çok, istenen girdi-çıkı davranışının örneklerini göstererek eğitmenin çok daha kolay olabileceğini bilmemektedir (Raut ve Borkar, 2017). Makine öğreniminin etkisi, bilgisayar biliminde ve tüketici hizmetleri, karmaşık sistemlerdeki arızaların teşhisi ve lojistik zincirlerinin kontrolü gibi veri yoğun konularla ilgilenen bir dizi endüstride de geniş bir şekilde hissedilmektedir. Yüksek verimli deneysel verileri yeni yöntemlerle analiz etmek için makine öğrenimi yöntemleri geliştirildiğinden, deneysel bilimlerde biyolojiden kozmolojiye ve sosyal bilimlere kadar benzer şekilde geniş bir etki yelpazesi olmuştur. Makine öğreniminin amacı verilerden öğrenmektir.


Makinelerin kendi kendilerine öğrenmesini sağlamak için birçok çalışma yapılmıştır (Welling, 2011, Bowles, 2015). Birçok matematikçi ve programcı, bu sorunun çözümünü bulmak için çeşitli yaklaşımlar uygulamaktadır.


2.5.3.Makine Öğrenme Modelleri

Makine Öğrenimi, bilgisayar bilimi ve mühendisliğinde birçok farklı disipline uygulanabilen en önemli araştırma konularından biridir. Makinelerde zekayı somutlaştırmayı mümkün kılan bir dizi algoritma, yöntem ve araç sağlar. Makine Öğreniminin gücü, belirli bir sorunu tanımlayan ve görünmeyen verilere geleneksel bir şekilde yanıt veren bir dizi veri ile eğitilebilen bir öğrenme prosedürü aracılığıyla sağlanan modelleme araçlarıdır.

Makine Öğrenmesi birçok model barındırmaktadır. Bu modeller Şekil 2.1 de gösterilmiştir. Bu çalışma havacılık sektöründe bilet fiyatlarının otomatik belirlenmesi konusuna odaklanmıştır. Bu bağlamda daha önce yapılmış çalışmalar ve kullanılmış modeller vardır.

Buradaki sınıflandırma, yapı (ağaç modeli, Düzenleştirme Yöntemleri gibi) veya yanıtlanacak soru türüne (regresyon gibi) dayanmaktadır. Bazıları birden çok kategoriye ayrılabilir, örneğin destek vektör makinesi (SVM) bir sınıflandırıcı olabilir ve ayrıca regresyon için kullanılabilir.





Şekil 2.1: Makine Öğrenmesi modelleri.

2.5.3.1. Regresyon

Regresyon, algoritmaya veya belirli bir problem tipine atıfta bulunabilir. Denetimli öğrenmedir. Regresyon, en eski ve en yaygın kullanılan istatistiksel modellerden biridir. Genellikle istatistiksel makine öğrenimi yöntemi olarak adlandırılır. Standart regresyon modelleri şunlardır:

- ✓ Adi En Küçük Kareler Regresyonu
- ✓ Lojistik regresyon
- ✓ Çok Değişkenli Uyarlanabilir Regresyon Uzanımları (MARS)
- ✓ Yerel Olarak Tahmini Dağılım Grafiği Düzeltme (LOESS)

En küçük kareler regresyonu ve lojistik regresyon geleneksel istatistiksel modellerdir. Her ikisi de son derece yorumlanabilir. MARS, orijinal öngörücüler yerine vekil öznitelikleri kullanmaları bakımından sinir ağlarına ve kısmi en küçük karelere (PLS) benzer.

Vekil özelliklerin nasıl oluşturulacağı konusunda farklılık gösterirler. PLS ve sinir ağları, vekil özellikler olarak orijinal öngörücülerin doğrusal kombinasyonlarını kullanır [Sinir ağlarında açık olmak gerekirse, öngörücülerin doğrusal kombinasyonları doğrusal olmayan aktivasyon fonksiyonları aracılığıyla konur, daha derin sinir ağlarında doğrusal olmayan dönüşümlerin birçok katmanı vardır]. MARS, bir kesme noktası ile bir tahmin edicinin iki zıt versiyonunu oluşturur. Ve LOESS, genellikle yalnızca görselleştirmede kullanılan parametrik olmayan bir modeldir.

2.5.3.2. Benzerliğe Dayalı Algoritmalar

Bu tür bir model, bir benzerlik ölçüsüne dayanmaktadır. Üç ana adım vardır:

1. yeni örneği mevcut olanlarla karşılaştırmak;

2. en yakın örneği aramak;
3. en yakın örneğin yanıtının tahmin olarak kullanılmasına izin verin.

- ✓ K-En Yakın Komşu [KNN]
- ✓ Vektör Nicilemeyi Öğrenme [LVQ]
- ✓ Kendi Kendini Düzenleyen Harita [SOM]

Bu tür modellerin en büyük avantajı sezgisel olmalarıdır. K-Nearest Neighbor genellikle bu kümedeki en popüler algoritmadır. Diğer ikisi daha az yaygındır. Benzerliğe dayalı algoritmaların anahtarı, verileriniz için uygun bir mesafe metriği bulmaktır.

2.5.3.3.Düzenleştirme Yöntemi

Bu yöntemin kendisi tam bir model değil, diğer modellere (regresyon modelleri gibi) bir eklentidir. Değişkenleri tahmin etmek için orijinal model tarafından kullanılan kriterlere bir ceza fonksiyonu ekler (olabilirlik fonksiyonu veya kare hatanın toplamı gibi). Bu şekilde model karmaşıklığını cezalandırır ve model parametrelerini daraltır. Bu yüzden insanlar onlara “büzülme yöntemi” diyorlar. Bu yaklaşım pratikte avantajlıdır.

- ✓ Sırt Regresyonu
- ✓ En Küçük Mutlak Büzülme ve Seçim Operatörü (LASSO)
- ✓ Elastik ağ

2.5.3.4.Karar ağacı

Karar ağaçları şüphesiz en popüler makine öğrenme algoritmalarından biridir. Her türlü yazılım sayesinde, uygulama, mekanizmanın neredeyse sıfır anlaşılmasını gerektiren beyinsizdir. Aşağıdakiler yaygın ağaçlardan bazılarıdır:

- ✓ Sınıflandırma ve Regresyon Ağacı (CART)
- ✓ Yinelemeli Dikotomizer 3 (ID3)
- ✓ Rastgele Orman
- ✓ Gradient Güçlendirme Makineleri (GBM)

2.5.3.5.Bayes Modelleri

İnsanlar genellikle Bayes teoremini Bayes modelleriyle karıştırırlar. Bayes teoremi, Bayesian veri analizine adını veren olasılık teorisinin bir uygulamasıdır.

Gerçek Bayes modeli, Bayes teoremi ile aynı değildir. Bir olasılık, tahmin edilecek parametreler ve her parametre için bir öncelik verildiğinde, bir Bayes modeli, tahminleri bu varsayımların tamamen mantıksal bir sonucu olarak ele alır. Ortaya çıkan tahminler, gözlemlere bağlı olarak, farklı parametre değerlerinin göreceli inanılabilirliği olan sonsal dağılımdır. Buradaki Bayes modeli, kesinlikle Bayes anlamında değil, Bayes teoremini kullanan bir modeldir.

- ✓ Naïve Bayes
- ✓ Ortalamalı Tek Bağımlılık Tahmincileri (AODE)
- ✓ Bayes İnanç Ağı (BBN)

2.5.3.6.Çekirdek Yöntemleri

En yaygın çekirdek yöntemi, destek vektör makinesidir (SVM). Bu tür bir algoritma, girdi verilerini, sınıflandırma veya regresyon problemlerinin çözülmesinin daha kolay olduğu daha yüksek dereceli bir vektör uzayına eşler.

- ✓ Destek Vektör Makinesi (SVM)
- ✓ Radyal Temel Fonksiyonu (RBF)
- ✓ Doğrusal Ayrım Analizi (LDA)

2.5.3.7.Kümeleme Yöntemleri

Regresyon gibi, insanlar kümelemeyi bahsettiğinde, bazen bir problem sınıfını, bazen bir algoritma sınıfını kastediyorlar. Kümeleme algoritması genellikle benzer örnekleri kategorilere göre merkezi veya hiyerarşik bir şekilde kümeler. İkisi en yaygın kümeleme yöntemleridir:

- ✓ K-Araçları
- ✓ Hiyerarşik kümeleme

2.5.3.8.Birliktelik Kuralı

Birliktelik kuralının temel fikri şudur: Olaylar birlikte meydana gelme oranlarından beklenenden daha sık meydana geldiğinde, bu tür bir birlikte oluşum ilginç bir modeldir. En çok kullanılan algoritmalar şunlardır:

- ✓ Apriori algoritması
- ✓ Eclat algoritması

2.5.3.9.Yapay Sinir Ağı

Sinir ağı terimi, bir model repertuarını ve öğrenme yöntemlerini kapsayacak şekilde gelişmiştir. Model ailesinin etrafında, onları büyümlü ve gizemli gösteren bir sürü yutturmaca var. Bir sinir ağı, iki aşamalı bir regresyon veya sınıflandırma modelidir. Temel fikir, orijinal öngörücülerin doğrusal kombinasyonlarını vekil özellikler olarak kullanması ve ardından 2. aşamada gizli birimleri elde etmek için yeni özelliklerin doğrusal olmayan aktivasyon fonksiyonlarından geçirilmesidir. Birden fazla gizli katman olduğunda, buna derin öğrenme denir, başka bir aşırı abartılmış terim. Sinir ağı modellerinin çeşitleri arasında en yaygın olarak kullanılan “vanilya” ağı, tek gizli katmanlı geri yayılım ağıdır.

- ✓ Perceptron Sinir Ağı
- ✓ Geri Yayılım
- ✓ Hopfield Ağı

2.5.3.10.Derin Öğrenme

Derin öğrenme, temelde üç veya daha fazla katmana sahip bir sinir ağı olan makine öğreniminin bir alt kümesidir. Bu nöral ağlar, insan beyninin davranışını simüle etmeye çalışır- yeteneğiyle eşleşmekten çok uzak olsa da- büyük miktarda veriden “öğrenmesine” izin verir. Tek katmanlı bir sinir ağı hala yaklaşık tahminler yapabilirken, ek gizli katmanlar doğruluğu optimize etmeye ve iyileştirmeye yardımcı olabilir. Bazı yaygın algoritmalar:

- ✓ Kısıtlı Boltzmann Makinesi (RBN)
- ✓ Derin İnanc Ağları (DBN)
- ✓ Evrişimsel Ağ (Convolutional Network)
- ✓ Yığılmış Otomatik Kodlayıcılar (Stacked Autoencoders)
- ✓ Uzun kısa-süreli hafıza (LSTM)

2.5.3.11.Boyutsal küçülme

Amacı, mümkün olduğu kadar çok varyansı yakalamak gibi önemli fiziksel veya istatistiksel özelliklere sahip yeni özellikler oluşturmaktır.

- ✓ Temel Bileşen Analizi (PCA)
- ✓ Kısmi En Küçük Kare Regresyon (PLS)
- ✓ Çok Boyutlu Ölçekleme (MDS)

✓ Açımlayıcı Faktör Analizi (AFA)

PCA, varyansı mümkün olan en büyük ölçüde açıklayabilen orijinal değişkenlerin ilişkisiz doğrusal kombinasyonlarını bulmaya çalışır. EFA ayrıca daha düşük bir boyutta mümkün olduğunca fazla varyansı açıklamaya çalışır. MDS, gözlemlenen benzerliği iki boyutlu bir düzlem gibi düşük bir boyuta eşler. MDS, altta yatan bileşenleri veya gizli faktörleri çıkarmak yerine, öğeler arasında gözlemlenen tüm benzerlikleri en iyi şekilde koruyan daha düşük boyutlu bir harita bulmaya çalışır. Bu nedenle kümeleme yöntemlerinde olduğu gibi bir benzerlik ölçüsü tanımlaması gerekir.

2.5.3.12. Topluluk Yöntemleri

Topluluk yöntemi 1990'larda ilk kez sahneye çıktı. Buradaki fikir, daha basit temel modeller koleksiyonunun güçlü yönlerini birleştirerek bir tahmin modeli oluşturmaktır. Başlangıçta Leo Breiman tarafından önerilen torbalama, en eski topluluk yöntemlerinden biridir. Ondan sonra Rastgele Orman ve Yükseltme yöntemi geliştirildi. Bu, güçlü ve etkili algoritmaların bir sınıfıdır (scientistcafe, 2017).

- ✓ Bootstrapped Toplama (Çuvallama)
- ✓ Rastgele Orman
- ✓ Gradyan Artırma Makinesi (GBM)

Chen ve diğ. (2015), 110 güne ilişkin gözlemleri kullanarak üç modelle çalışmış ve Learn ++. NSE'nin KNN ve Pasif-Agresif 'ten daha iyi performans gösterdiği sonucuna varmıştır. Lantseva ve diğ. (2015), iki farklı Küresel Dağıtım Sisteminden toplanan verileri terk etmek için 75 ve 90 gün süren deneysel veriye dayalı bir Regresyon Modeli kullanmıştır. Model, kalkış tarihinden önceki 90 gün içinde belirli bir uçuş için kilometre başına fiyatı tahmin eder. Li ve Li (2018), rastgele bir orman algoritması ile bir ARMA kombinasyonu önermiştir. Abdella ve diğ. (2019) uçak bileti fiyatı ve tahmin çalışmalarını araştırmış ve anketinin özetini tablo haline getirmiştir. Chung ve diğ. (2020), veri bilimi ve analitiğinin Makine Öğrenimi de dahil olmak üzere dört farklı alanda kullanımı hakkında bir çalışma yapmıştır.

Tziridis ve diğ. (2017), son teknoloji Makine Öğrenimi algoritmalarının sekiz durumu üzerinde çalışmış ve bu sonuçları karşılaştırmıştır. Yapay Sinir Ağları (YSA), deneyim ve bilgiye dayalı olarak insan beynini taklit eden algoritmik bir Makine Öğrenimi teorisidir. İş dünyasında

yaygın olarak kullanılan YSA, güçlü bir tahmin aracıdır ve karmaşık sorunları çözmek için geleneksel modellerden daha iyi tahminler sağlayabilir.

Son zamanlarda birçok güçlü model de tanıtılmıştır. Panda ve Panda (2020), model eğitimini hızlandırmak için geri yayılım öğrenme kurallarını tanıtmıştır. Altan ve diğ. (2019), Cuckoo Search (CS) algoritması ile birlikte Long Short-Term Memory (LSTM) sinir ağı ve Ampirical Wavelet Transform (EWT) ayrıştırmasına dayalı bir hibrit tahmin modeli geliştirmiştir. Karasu ve diğ. (2020), çok amaçlı bir optimizasyon tekniği kullanarak sarmalayıcı tabanlı özellik seçimi yaklaşımıyla Destek Vektör Regresyonuna (SVR) dayalı yeni bir tahmin modeli ile çalışmıştır. Altan ve diğ. (2020), koronavirüs pnömonisi ile enfekte olmuş hastayı X-ışını görüntülerinden belirlemek için iki boyutlu (2D) curvelet dönüşümü, Chaotic Salp Swarm Algorithm (CSSA) ve derin öğrenme tekniğinden oluşan hibrit bir model geliştirmiştir.

Qin ve diğ. (2017), Çift Aşamalı Dikkat Temelli Tekrarlayan Sinir Ağını (DA-RNN) tanıtmıştır. RNN'ler, girişin yanı sıra mevcut durumu da dikkate alan bir YSA türüdür. Kodlayıcı ve kod çözücüde iki farklı dikkat mekanizması kullanan DA-RNN, en uygun giriş özelliklerini uyarlamalı olarak seçer ve bir zaman serisinin uzun vadeli geçici bağımlılıklarını yakalar. Qin ve diğ. (2017) DA-RNN bulgularını ARIMA, NARX RNN ve Encode-Decoder algoritmalarıyla karşılaştırmış ve DA-RNN'nin diğerlerinden daha iyi performans gösterdiğini göstermiştir.

LSTM'ler, uzun vadeli bağımlılıkları öğrenebildikleri için ortadan kaybolan gradyan problemi için bir çözüm olarak tanıtılmıştır. Guo ve diğ. (2019) Yorumlanabilir Çok Değişkenli Uzun Kısa Süreli Belleği (IMV-LSTM) tanıtmıştır ve bu modelin yapısal zaman serisi modelleri, DA-RNN, Extreme Gradient Boosting, ARIMAX, Elastic-Net, Random Forests, ve RNN algoritmalarından daha iyi performans gösterdiğini bildirmiştir.

2.5.3.13. Makine Öğrenimini Kullanan Sektörler

Sağlık hizmeti: Nabız hızı ve adım adımlarından oksijen ve şeker seviyelerine ve hatta uyku düzenine kadar her şeyi izleyen giyilebilir sensörlerin ve cihazların yaygınlaşması, doktorların hastalarının sağlığını gerçek zamanlı olarak değerlendirmelerini sağlayan önemli miktarda veri üretti. Yeni bir makine öğrenimi algoritması, mamogramlarda kanserli tümörleri tespit eder; bir diğeri cilt kanserini tanımlar, üçüncüsü, diyabetik retinopatiyi teşhis etmek için retina görüntülerini analiz edebilir.

Hükümet: Makine öğrenimini kullanan sistemler, hükümet yetkililerinin potansiyel gelecek senaryolarını tahmin etmek ve hızla değişen durumlara uyum sağlamak için verileri kullanmasını sağlar. Makine öğrenimi, siber güvenliği ve siber istihbaratı iyileştirmeye, terörle mücadele çabalarını desteklemeye, operasyonel hazırlık, lojistik yönetimi ve kestirimci bakımı optimize etmeye ve arıza oranlarını azaltmaya yardımcı olabilir. Bu son makale, sağlık sektöründe makine öğrenimi için 10 uygulamayı daha vurgulamaktadır.

Pazarlama ve Satış: Birçok şirket, müşteri memnuniyetini %10'un üzerinde artırmak ve artırmak için yapay zekâ (AI) ve makine öğrenimini başarıyla uyguladığından, makine öğrenimi pazarlama sektöründe devrim yaratıyor. Aslında, Forbes'a göre, "Kurumsal yöneticilerin %57'si, yapay zekâ ve makine öğreniminin en önemli büyüme avantajının müşteri deneyimlerini ve desteğini iyileştirmek olacağına inanıyor.

E-ticaret: Sipariş ve arama tarihçemizi analiz ederek kişiselleştirilmiş ilgi alanlarımıza bağlı olarak arz edilebilecek diğer ürünler ile ilgili tavsiyelerde bulunabilmek için de sosyal medya siteleri ve E-ticaret siteleri makine öğrenimini kullanmaktadır. Pek çok uzman, derin öğrenme iş uygulamaları, kişilerin yukarıda ifade edilen tarihçesine bağlı olarak hedefli pazarlama kampanyaları düzenleyebilmek amacıyla önceki verileri kayıt altına alma, analiz etme ve sonuç çıkarma konusunda uzmanlaştıkça, perakendenin geleceğinin yapay zekâ ve makine öğrenimi tarafından yönlendirileceğini kuramlaştırıyor.

Ulaşım: Verimlilik ve doğruluk, bu sektörde karlılığın anahtarıdır; potansiyel sorunları tahmin etme ve azaltma yeteneği de öyle. Makine öğreniminin veri analizi ve modelleme işlevleri, teslimat, toplu taşıma ve yük taşımacılığı sektörlerindeki işletmelerle mükemmel bir uyum içindedir. Makine öğrenimi, bir tedarik zincirinin başarısını olumlu ve olumsuz yönde etkileyen faktörleri bulmak için algoritmalar kullanır ve makine öğrenimini tedarik zinciri yönetiminde kritik bir bileşen haline getirir.

Lojistik: Makine öğrenimi, zamanlayıcıların taşıyıcı seçimi, derecelendirme, yönlendirme ve kalite kontrol süreçlerini optimize etme becerisini kolaylaştırır, bu da para tasarrufu sağlar ve verimliliği artırır. Makine öğreniminin binlerce veri noktasını aynı anda analiz etme ve algoritmaları herhangi bir insandan daha hızlı uygulama yeteneği, makine öğreniminin insanların henüz tanımlamadığı sorunları çözmesini sağlar.

Finansal hizmetler: Bu sektördeki makine öğreniminin sağladığı içgörüler, yatırımcıların oluşacak fırsatları yakalamalarında veya ticaretin yapılması gereken zamanı belirlemelerine olanak tanır. Veri madenciliği, dolandırıcılık yönetimi kapsamında riskli müşterilerin tespitinde de kullanılmaktadır. Makine öğrenimi, finansal portföyleri düzenlemeye veya krediler ve sigorta aracılık risklerini değerlendirmede kullanılabilir.

Bu sektördeki yapay zekâ ve makine öğreniminin geleceği, finansal önerilerde bulunmak için riskten korunma fonlarını değerlendirme ve borsa hareketini analiz etme becerisini içerir. Makine öğrenimi, anormallik algılamayı bir sonraki düzeye taşıyarak kullanıcı adlarını, parolaları ve güvenlik sorularını geçersiz hale getirebilir: yüz veya ses tanıma veya diğer biyometrik veriler.

Yağ ve gaz: Makine öğrenimi ve yapay zekâ, yeni enerji kaynaklarının aranmasında ve potansiyel ve gerçek maden yataklarını analiz etmek, arıtma istasyonlarındaki sensör arızalarını tahminleyebilmek, verimliliği artırmak ve giderleri azaltmak için de kullanılmaktadırlar. Makine öğrenimi, vaka tabanlı akıl yürütme, rezervuar modelleme ve sondaj zemini otomasyonu da sektörde devrim yaratıyor. Ve hepsinden önemlisi, makine öğrenimi bu tehlikeli endüstriyi daha güvenli hale getirmeye yardımcı oluyor.

İmalat: Makine öğrenimi imalat endüstrisinde üretim süreçlerinin hemen hemen her aşamasında operasyon optimizasyonu, kalite oranlarını artırma, hatalı ürün üretim oranını azaltma ve envanter yönetimini gerçekleştirmekte kullanılmaktadır.

Taşımacılık endüstrisinden farklı olarak, makine öğrenimi şirketlerin varlıkları, tedarik zincirini ve envanter yönetimini içeren lojistik çözümleri geliştirmesine yardımcı olmaktadır. Makine öğrenimi, montajda kullanılan cihazların verimliliğini, kalitesini ve başarımlar oranını ölçerek genel donanım yeterliliğini (OEE) artırmada da kullanılmaktadır (Quantilus, 2020).

2.6. HAVAYOLU GELİR YÖNETİMİ

Bir havayolu şirketi, genellikle, çeşitli ücret sınıflarında birçok kalkış-varış güzergahı için bilet sunar. Bu ücret sınıfları, yalnızca uçağın ayrı bölümlerine yerleştirilen işletme ve ekonomi sınıflarını değil, aynı zamanda ücretlerdeki farkın, örneğin iptal seçenekleri veya geceleme düzenlemeleri gibi farklı koşullarla açıklandığı ücret sınıflarını da içerir. Bu nedenle uçuştaki

koltuklar, farklı fiyatlar için farklı müşteri segmentlerine sunulabilen ürünlerdir. Bir uçuş için biletlerin uçak kalkmadan satılması gerektiğinden ürün bozulabilir ve gelir yönetimi uygulanabilir.

Havayolu gelir yönetiminin merkezinde koltuk envanter kontrolü sorunu yatar. Bu sorun, uçuşun kalkması planlanmadan önce zaman içinde meydana gelen talebe sınırlı koltuk envanterinin tahsisi ile ilgilidir. Amaç, uçuşlarda gelirleri maksimize edecek doğru yolcu kombinasyonunu bulmaktır. Koltuk envanterinin optimal tahsisi, daha sonra, geldiğinde bir rezervasyon talebinin kabul edilip edilmeyeceğini belirleyen bir rezervasyon kontrol politikasına çevrilmelidir. Daha sonraki bir zamanda başka bir yolcunun rezervasyon talebini kabul edebilmek için belirli bir zamanda bir rezervasyon talebini reddetmek daha karlı olabilir.

Gelir yönetimi literatüründe dikkat çeken diğer önemli konular talep tahmini, çifte rezervasyon ve fiyatlandırmadır. Talep tahmini, havayolu gelir yönetiminde kritik öneme sahiptir çünkü rezervasyon kontrol politikaları, optimum rezervasyon kontrol stratejisini belirlemek için talep tahminlerinden yararlanır. Bir havayolu kötü talep tahminleri kullanırsa, bu kötü performans gösteren bir rezervasyon kontrol stratejisine neden olur. Havayolları genellikle rezervasyonsuz, iptal ve reddedilen binişlerle başa çıkmak zorundadır. Bu nedenle, bir uçuşun boş koltuklarla kalkmasını önlemek için, havayolları bir uçuş için fazladan rezervasyon yapma eğilimindedir. Bu, havayolunun bir uçuşta uçağın kapasitesinin izin verdiği daha fazla yolcu ayırdığı anlamına gelir. Her yolcu türü için çifte rezervasyon seviyesi, uzun yıllardır araştırma konusu olmuştur. Bir havayolu şirketinin gelirleri için fiyatlandırma tabii ki çok önemlidir. Aslında, fiyat farklılaştırması, gelir yönetimi kavramının başlangıç noktasıdır.

Havayollarında Gelir Yönetimi, envanter kontrolünün otomatikleşmesine, düşük talepli uçuşlarda yüklerin artırılmasına ve yüksek talepli uçuşlarda verimin artırılmasına olanak tanır.

Uçuş envanteri ayarları, her uçuş için gelir sonucunu kontrol eder. Bu ayarlar, tam olarak hangi sınıflara ve fiyatlara sahip olunduğunu ve her fiyat noktasındaki kapasite uygunluğunu belirler.

Uçuşlar talep gruplamalarına göre uçuş kontrolörleri, gelir yöneticiler veya veri analistleri tarafından manuel olarak yönetiliyor olabilir, düşük talepli günler, orta talepli günler ve yüksek talepli günler için farklı envanter ayarları oluşturulur. Manuel kontrole ilgili sorun, aynı kategorideki (düşük, orta veya yüksek) tüm uçuşların aynı şekilde performans göstereceğini

varsaymasıdır, bu da havayolu için her gün görülmeyen ancak önemli kayıplar yaratır (Pak ve Piersma).

2.7. HAVAYOLU BİLET FİYAT TAHMİNLEMESİ

Havayolu endüstrisi, karmaşık fiyatlandırma stratejileri kullanan en gelişmiş endüstrilerden biri olarak kabul edilir. Günümüzde bilet fiyatları, yandaki koltuk için bile aynı uçuş için dinamik ve önemli ölçüde değişebilir (Etzioni ve diğ., 2003, Narangajavana ve diğ., 2014). Belirli bir uçuşun bilet fiyatı günde 7 defaya kadar değişebilir (Etzioni ve diğ., 2003). Müşteriler biletleri için en düşük fiyatı almaya çalışırken, havayolu şirketleri toplam gelirlerini olabildiğince yüksek tutmaya ve karlarını en üst düzeye çıkarmaya çalışmaktadır. Ancak, mevcut koltuklar ile yolcu talebi arasındaki uyumsuzluklar genellikle ya müşterinin daha fazla ödeme yapmasına ya da havayolu şirketinin gelir kaybına neden olur. Havayolu şirketleri genellikle fiyatlandırma sürecini kontrol etmelerini sağlayan gelişmiş araç ve yeteneklerle donatılmıştır. Bununla birlikte, çeşitli havayolu şirketlerinde fiyatları karşılaştırmak için çeşitli çevrimiçi araçların geliştirilmesiyle müşteriler daha stratejik hale gelmektedir (Li ve diğ., 2014). Ek olarak, havayolları arasındaki rekabet, en uygun fiyatı belirleme görevini herkes için zorlaştırmaktadır.


Son yirmi yılda hem müşterileri hem de havayollarını hedefleyen araştırmaların giderek arttığı görülmektedir. Müşteri tarafı araştırmaları müşteri için para tasarrufu sağlamaya odaklanırken, havayolu tarafı araştırmaları havayollarının gelirini artırmayı amaçlamaktadır. Yürütülen araştırmalar, regresyon gibi istatistiksel tekniklerden farklı türlerde gelişmiş veri madenciliği tekniklerine kadar çeşitli teknikler kullanır.

Müşteri bakış açısından, bilet almak için minimum fiyatı veya en iyi zamanı belirlemek temel konudur. "Önceden satın alınan biletler daha ucuzdur" anlayışı artık işlememektedir (Groves ve Gini, 2013). Daha önce bilet alan müşterilerin, daha sonra aynı bileti alanlara göre daha fazla ödeme yapması mümkündür. Ayrıca, erken satın alma, genellikle bir ücret karşılığında değiştirilmesi gerekebilecek belirli bir programa bağlılık riskini ifade eder. Bilet fiyatı çeşitli faktörlerden etkilenebilir ve bu nedenle sürekli değişebilir. Bunu ele almak için, müşteriye en uygun bilet satın alma süresini ve bilet fiyatı tahminini belirlemede desteklemek için çeşitli çalışmalar yapılmıştır (Lantseva ve diğ., 2015, Chawla ve Kaur, 2017, Domínguez-Menchero ve diğ., 2014; Tziridis ve diğ., 2017, Li ve diğ., 2014, Santana ve Saulo, 2017, Li ve Chu, 2017, Wohlfarth ve diğ., 2011, Vu ve diğ., 2018, Groves ve Gini, 2013, Groves ve Gini, 2015, Y.

Chen ve diğ., 2015, Xu ve Cao, 2017). Müşteri tarafında gerçekleştirilen çalışmaların çoğu, istatistiksel yöntemler kullanarak optimum bilet satın alma süresini tahmin etme sorununa odaklanmaktadır. Chen ve diğ. (2015), gerçek bilet fiyatını tahmin etmek, çeşitli nedenlerden dolayı optimum bilet satın alma süresini tahmin etmekten daha zor bir iştir: yeterli veri kümesinin olmaması, bilet fiyatlarını etkileyen dış faktörler, bilet fiyatlandırmasının dinamik davranışı, havayolları arasındaki rekabet, havayolları bilet fiyatlandırma politikaları vb. Bununla birlikte, çok az çalışma gerçek bilet fiyatlarını tahmin etmeye çalışmıştır (Lantseva ve diğ., 2015, Domínguez-Menclero, 2014, Tziridis ve diğ., 2017, Santana ve Saulo, 2017, Li ve Chu, 2017, Vu ve diğ., 2018).

Havayolları tarafında ise asıl amaç geliri artırmak ve kârı en üst düzeye çıkarmaktır. Narangajavana ve diğ., (2014)'e göre, havayolları, optimum bilet fiyatlarını belirlemek için çeşitli fiyatlandırma stratejileri kullanır: uzun vadeli fiyatlandırma politikaları, üretim koşullarının bilet fiyatları üzerindeki etkisini tanımlayan getiri fiyatlandırması ve esas olarak dinamik ile ilişkilendirilen dinamik fiyatlandırma çeşitli etkileyen faktörlere yanıt olarak bilet fiyatlarının ayarlanması. Uzun vadeli fiyatlandırma politikaları ve getiri fiyatlandırması, belirli bir havayolunun dahili çalışmasıyla ilişkilidir ve fiyattaki dinamik dalgalanmaları tahmin etmede o kadar da yardımcı olmaz. Öte yandan, dinamik fiyatlandırma, talepteki değişiklikler ve fiyat farklılaştırması gibi canlı faktörlere dayalı olarak bilet fiyatlarının daha optimal bir şekilde tahmin edilmesini sağlar (Malighetti ve diğerleri, 2009). Bununla birlikte, dinamik fiyatlandırma, iç faktörler, dış faktörler, havayolları arasındaki rekabet ve stratejik müşteriler gibi çeşitli faktörlerden oldukça etkilendiği için zordur. İç faktörler, geçmiş bilet fiyatı verileri, bilet satın alma tarihi ve kalkış tarihi, sezon, tatiller, ikmal (mevcut havayolu ve uçuş sayısı), ücret sınıfı, koltuk kullanılabilirliği, son piyasa talebi ve uçuş mesafesi gibi özelliklerden oluşur. Dış etkenler, başlangıç veya varış şehirde terör saldırıları, doğal afet (kasırga, deprem, tsunami vb.), Siyasi istikrarsızlık (protesto, grev, darbe, istifa), siyasi toplantılar ve spor etkinlikleri, rakiplerin promosyonları, hava koşulları, ekonomik faaliyetler, konserler, festivaller, konferanslar gibi bazı olayların meydana gelmesi gibi özellikleri içerir.

Dinamik fiyatlandırmanın belirlenmesinde müşteriler ve havayolları arasındaki etkileşimleri gösteren bir şema Şekil 2.2'de verilmiştir.



Şekil 2.2: Dinamik fiyatlandırma.

Genel olarak dinamik fiyatlandırma, perakendeci ve tüketiciler arasında her bir tarafın kendi karını maksimize etmeye çalıştığı bir oyun olarak düşünülebilir (Wang, 2016). Havayolları, mümkün olduğunca çok sayıda bileti en yüksek fiyata satarak karlarını artırma arzusuna sahiptir. Ancak, uzun süre beklemek satılmayan koltuklar nedeniyle daha fazla kayba neden olabileceğinden, biletlerin sınırlı bir süre içinde satılması gerekir. Öte yandan müşteriler, en düşük fiyattan bilet almayı ve bilet fiyatı düşene kadar havayolları genelinde bilet fiyatlarını izlemeye devam etmeyi sürdürmektedirler. Dahası, müşteriler rastgele gelir ve talep zaman zaman değişebilir. Bu nedenle, bu tür karmaşık durumlarda karlı olabilmek için havayolları, mevcut talebe, müşterilerin davranışlarına, pazardaki rakipler tarafından verilen bilet fiyatlarına ve diğer iç ve dış faktörlere göre bilet fiyatlarını dinamik olarak ayarlamalıdır (Wang, 2016, Chen ve Farias, 2015). Çeşitli etken faktörlere yanıt olarak bilet fiyatlarının bu dinamik ayarlaması, dinamik fiyatlandırma olarak bilinir. Yukarıda belirtilen çalışmalar (Malighetti ve diğ., 2009, Narangajavana ve diğ., 2014, Wang, 2016, Chen ve Farias, 2015) dinamik fiyatlandırmanın en yaygın fiyat stratejilerinden biri olarak havayolları tarafından uygulandığını açıklamaktadır.

2.8. HAVAYOLU GİDERLERİ VE KARLILIK

Temel olarak, havayolu maliyetleri DOC (Doğrudan İşletim Maliyetleri: Yer Hizmetleri, Havaalanı Giderleri, Akaryakıt, Rota), ACMI (Uçak, Mürettebat, Bakım, Sigorta) ve IOC

(Dolaylı İşletim Maliyetleri: Binalar Ekipman, Nakliye, Yer personeli... v.b.) olarak sınıflandırılabilir. Bu sınıflandırma Tablo 2.1’de gösterilmiştir.

Tablo 2.1: Havayolları maliyetlerinin yapısı.

Doğrudan İşletme Maliyetleri	ACMI	Dolaylı İşletme Maliyetleri
Yer Hizmetleri	Uçak	Binalar, Ekipman
Havaalanı Hizmetleri	Mürettebat	Yolcu Hizmetleri
Akaryakıt	Bakım	Biletleme, Satış, Promosyon
Rota	Sigorta	Genel yönetim ve diğerleri

Havayollarının maliyetlerin ağırlık oranları firmanın operasyonuna göre değişiklik arz etmektedir. Geniş gövdeli uçaklarla daha uzun mesafeli uçuşlarla operasyon yapan bir havayolunun maliyetlerinin dağılımı, daha dar gövdeli uçuklar ile daha kısa mesafelere operasyon yapan havayolunun maliyetlerinin dağılımı farklı sonuçlar üretir. Bu farkı göstermek için örnek olarak seçilen iki havayolunun ve maliyetler oranlarının karşılaştırılması Tablo 2.2’de gösterilmiştir.

Havayolu yönetimi maliyet etkenlerinin bazıları üstünde çok az etki sahibi ilen diğerleri üstünde yüksek etkiye sahip olabilirler. Söz konusu etki Tablo 2.3’de gösterilmiştir.

Havayolları, tüm bu parametrelerden bir uçuş için CASK (Müsait Koltuk Kilometresi Başına Maliyet) değerini hesaplar. Arz, mevcut koltuk kapasitesi olmasına rağmen, yük faktörünün kendisi fiyatın bir fonksiyonudur. Dolayısıyla gelir sistemi tüm bu maliyetleri karşılamalı ve ayrıca bir katkı payı vermelidir. Maliyetin toplamı ve katkı tutarı Hedef Geliri belirler. Bu miktar, beklenen yıllık performans göre hesaplanır ve bu nedenle, düşük sezonlarda bu miktar sıfırın altında olabilir. Şekil 2.3 ve 2.4’de, kalkış tarihinden 61 gün önceki düşük ve yoğun sezonların tek bir uçuşunun toplam gelirinin hesaplandığı iki örnek verilmiştir. Noktaların boyutu, satılan koltuk sayısını gösterir. Renkli noktalar, söz konusu uçuşun toplam gelirinin mevcut miktarını gösterir. Kırmızı noktalar kümülatif gelirin IOC altında olduğunu, sarı noktalar kümülatif gelirin DOC altında olduğunu, mavi noktalar kümülatif gelirin ACMI altında olduğunu, yeşil noktalar kümülatif gelirin Hedef Gelir altında olduğunu ve mor noktalar ise kümülatif gelir Hedef Gelirin üzerindedir.

Tablo 2.2: Uzun ve kısa mesafeli havayollarının zıt maliyet yapısı, 2007 mali yılı.

<i>Average sector length</i>	<i>Composition of costs</i>	
	<i>Bmi (British Midland) 760 kms %</i>	<i>Virgin Atlantic 7,270 kms %</i>
A: DIRECT COSTS		
1 Flight operations		
Flight crew	7.3	4.5
Fuel	20.6	27.6
Airport and en-route	20.7	7.1
Insurance	0.7	0.2
2 Maintenance	11.2	8.7
3 Depreciation/lease, rentals	10.4	12.4
TOTAL DIRECT	70.9	60.5
B: INDIRECT COSTS		
4 Station and ground costs	10.2	5.4
5 Passenger services* (inc. cabin crew costs)	6.1	13.6
6 Ticketing, sales and promotion	8.4	7.9
7 Admin and other costs	4.3	12.6
TOTAL INDIRECT	29.1	39.5
C: TOTAL OPERATING COSTS	100.0%	100.0%


Source: Compiled using CAA (2009a).

Note


* Bmi's financial year to end December 2007, Virgin's to end February 2008.

Tablo 2.3: Havayolu işletme maliyetlerini etkileyen faktörler.

	Yönetimin kontrol derecesi
Dışarda belirlenen girdi maliyetleri	Az
İşçilik maliyeti	Orta
Filo uçak tipleri / özellikleri	Orta
Rota yapısı / ağ özellikleri	Orta
Havayolu pazarlama ve ürün politikası	Çok
Havayolu finansman politikası	Çok
Kurumsal strateji	Çok
Yönetimin kalitesi	Çok



Şekil 2.3: Düşük sezon için kümülatif gelir grafiği örneği.




Şekil 2.4: Yüksek sezon için kümülatif gelir grafiği örneği.

Genel olarak, belirli bir güzergâh için toplam gelirlerin yüksek oranı, bunun en karlı yol olduğu anlamına gelmez. Şekil 2.5'te, mavi çizgi RASK'yı (Kullanılabilir Koltuk Kilometresi Başına Gelir), kırmızı çizgi CASK'yı ve yeşil çizgi RASK ile CASK arasındaki farkı temsil eder. (Bu grafikler, İstanbul'dan 17 şehre / havalimanına yapılan uçuşlardan toplanan veriler kullanılarak çizilmiştir).

Şekil 2.5'dan görülebileceği gibi, en yüksek gelire Odessa uçuşları sahipken, en yüksek kar Bodrum'a aittir. Bu nedenle, CASK verileri de bu çalışmada gelir maksimizasyonu yerine kar maksimizasyonu için ele alınmıştır.

2.9. UÇAK BİLET FİYATININ BELİRLENMESİ VE REGRESÖRLER

Uçak bilet fiyatlarının belirlenmesi süreci çok karmaşıktır ve birçok etken rol oynamaktadır. Bu etkenlerin belirlenmesi için oldukça fazla sayıda akademik ve ticari çalışmalar yapılmıştır.



Şekil 2.5: İstanbul kalkışlı güzergahların RASK-CASK değer karşılaştırmaları.

Havayollarının fiyatları ayarlama talebi, sabit koltuk envanterine dayanmaktadır. Varedi (2010), müşterilerin tercihleri hakkındaki bilgilerin sınırlı olması ve iş ortamının hızla değişmesi nedeniyle yolcu talebini tahmin etmenin zorluğunun altını çizmiştir. Chiou ve Liu (2016), uçak yolcularının önceden satın alma davranışlarını incelemiş ve bu davranışın, havayollarının dinamik fiyatlandırma stratejileri ile değişebileceğini belirtmiştir.

Groves ve Gini'ye (2011) göre bu alanda matematiksel yöntemler geliştirmek için yapılan çalışmalar, büyük ölçekli optimizasyon modellerine ve problemin basitleştirilmiş resimlerine

odaklanmıştır. Bu nedenle, nicel karar araçlarını içeren pratik çözüm yaklaşımlarına ihtiyaç vardır. Öte yandan gelirleri maksimize etmek için birçok çalışma yapılmıştır.

Başarılı yönetim, etkili bir verimlilik ile gelirleri artırmayı düşünebileceğinden, birçok havayolu, koltuk envanter kontrol sürecinin her yönünü iyileştirmeyi düşünmüştür. Koltuk envanterlerinin satışını yönetmenin daha iyi yollarını bulmak için bir rekabet haline gelen havayolları, sorumlu departmanları genişletmekte ve yeniden organize etmekte, rezervasyon sistemlerini yükseltmekte ve sofistike karar destek sistemleri geliştirmektedir. Havayolu endüstrisindeki getiri yönetimi, neredeyse tamamen insan uzmanlığına dayanan sanattan daha sistematik analiz ve karar teknikleri kullanan bilime doğru gelişen bir geçiş aşamasındadır (Groves ve Gini, 2011).

Wen & Chen (2017), düşük maliyetli havayollarının ücretlerinin yüksek esnekliğinin altını çizmektedir. Bu nedenle, bu operatörler bazen bilet promosyonları sunmakta ve bu nedenle ücretler haftanın her günü değişebilmektedir. Brons ve diğ. (2002) yolcu hava taşımacılığı talebinin bir dizi ekonomik, demografik ve coğrafi regresörlerini ve bununla ilişkili fiyat esnekliğini tartışmışlardır.

Önemli sayıda güncel araştırma çalışması, havayolları için dinamik fiyatlandırma için tahmin modelleri önermiştir. Bir makine öğrenme modeli eğitmek için, çoklu belirleyiciler, hedef seriyi tahmin etmek için modele girdi olmak üzere dışsal zaman serileri olarak kullanılabilir. Papadakis (2012) bazı özellikleri saymış ancak sadece boş koltukları, dikkate alınan rotadaki rekabeti, kalkışa kalan gün sayısını, biletteki fiyat değişikliklerini ve bilet fiyatlarındaki dalgalanmaları dikkate almıştır. McHugh (2018) kalkış havaalanını, varış havaalanını, haftanın gününü, yılın haftasını, uçuş süresini, kalkışa kadar kalan günleri kullanmıştır. Varedi (2010), kalkış ve varış havaalanı, uçuş numarası, uçuş kalkış tarihi, uçuş kalkış saati, uçak kapasitesi, anlık görüntü-tarih, günlük rezervasyon sayısı, toplam iptaller, düzenli müşteriler için rezervasyonlar toplamı içeren Kuzey Amerika havayolu şirketi tarafından sağlanan verileri kullanmıştır. Tziridis ve diğ. (2017), kalkış saati, varış saati, ücretsiz bagaj numarası (0, 1 veya 2), kalkışa kalan gün sayısı, transfer sayısı, uçuş tarihinin tatil olup olmadığını, uçuşun gece olup olmadığını, haftanın gününü dikkate almıştır. Brons ve diğ. (2002) yolcu hava taşımacılığı talebi ve fiyat esnekliği ile ilgili çeşitli ekonomik, demografik ve coğrafi regresörleri tartışmıştır. Bu çalışmaların sonucu Tablo 2.4’de özetlenmiştir.

Tablo 2.4: Dinamik bilet fiyatlandırma için kullanılan özellikler.

	McHugh (2018)	Varedi (2010)	Tziridis ve diğ. (2017)	Mottini, ve Acuna-Agost, (2017)	Airline Web	Papadakis (2012)	Bu çalışma
Kalkış Havaalanı				✗			✗
Varış Havaalanı	✗			✗			✗
Haftanın günü	✗	✗	✗	✗	✗		✗
Yılın haftası	✗	✗			✗		✗
Uçuş süresi	✗	✗		✗			
Uçuşa kalan gün sayısı	✗	✗	✗	✗	✗	✗	✗
Daha önce satılan koltukların sırası	✗						
Önceki fiyatların sırası		✗				✗	
Fiyat değişiklik sırası		✗	✗			✗	
Kalkış zamanı			✗	✗	✗		
Varış zamanı			✗	✗			
Tatil günü mü			✗				✗
Fiyat				✗			✗
Kalan koltuk kapasitesi						✗	✗
Rakiplerin fiyatı							✗
Uçulan koltuk kilometer maliyeti (CASK)							✗
Hedef gelir							✗

3. MALZEME VE YÖNTEM

3.1.VERİ

Yukarıda bahsedilen çalışmalar ışığında, aşağıda listelenen regresörlerin maliyet ve gelirle ilgili bazı özellikler ekleyerek bu çalışmada kullanılması uygun görülmüştür. Sadece İSTANBUL-DÜSSELDORF (IST-DUS) güzergahı incelenmiştir. Günde sadece bir uçuş olduğu için, regresör olarak, varış saatini ve uçuş süresini dikkate almaya gerek görülmemiştir.


- Kalkış Havaalanı, (İstanbul-Türkiye)
- Hedef Havaalanı, (Düsseldorf-Almanya)
- Haftanın günü,
- Yılın haftası,
- Kalkışa Kalan Günler, (Satış Tarihi-Uçuş Tarihi)
- Tatil mi, (Evet veya hayır)
- Fiyat, (Günde sadece bir uçuş olduğu için bilet fiyatları dikkate alınır)
- Kullanılabilir Koltuk Kapasitesi,
- Rakip^{1,2,3} Fiyat, (Bu rota için başka üç havayolu rakip olarak yer almaktadır. Rakiplerin belirli bir tarih için birden fazla uçuşu mevcuttur. Ortalama haftalık minimumları özellik olarak alınmıştır. İstanbul'da iki havalimanı vardır ve her iki havaalanı da dikkate alınmıştır.
- CASK Değeri: Verilen rota ve tarih için Kullanılabilir Koltuk Kilometre başına maliyet
- Hedef Gelir: Hedef gelir değeri

Burada özellikle son iki özellik, önceki literatür çalışmalarında bilgimiz dahilinde dikkate alınmamış olan Maliyet ve Hedef Geliri bu çalışmada dikkate alınmaktadır.

Türkiye merkezli düşük maliyetli bir havayolu şirketinden alınan gerçek veriler bu çalışmada kullanılmıştır. Rakiplerin haftalık bazda bilet fiyatları alınmış ve kullanılmıştır. Gözlem verileri 24.264 satırdan oluşmaktadır. Şekil 3.1 ve 3.2, hareket tarihinden 61 gün önce başlayan satışları temsil eden iki örnektir. Noktaların boyutu, satılan koltuk sayısını gösterir. Şekil 3.1 ve 3.2, Şekil 2.4 ve 2.5'i elde etmek için kullanılan aynı veriler kullanılarak elde edilmiştir. Beşinci dereceden eğilim çizgisi de çizilir ve bu çizginin dalga biçimi yerine uçuş tarihi yaklaştıkça


sürekli olarak artması beklenir. Dalga biçimleri, rakip fiyat değişikliklerine hızlı yanıt verilmesi veya önemli miktarda gelir kaybına neden olabilecek panik fiyat konumlandırması nedeniyle oluşur.

Ortalama Fiyat – 19 Şubat 2018




Şekil 3.1: Düşük sezon için satış grafiği.

Ortalama Fiyat – 19 Ağustos 2018



Şekil 3.2: Yüksek sezon için satış grafiği.

Çalışma, 15 Haziran 2017 ile 12 Haziran 2019 tarihleri arasında toplanan verilere dayanmaktadır. Havayolunun verileri IST-DUS güzergahına aittir ve sadece tek yön biletleri dikkate alınmıştır. Aynı güzergâh için Türk Hava Yolları, Atlas Global ve Pegasus adında üç rakip bulunmaktadır ve hepsinin günde birden fazla uçuşu vardır. Rakip fiyatları haftalık ortalama olduğu için her bir rakibin minimum fiyatları özellik olarak seçilmiştir. Bu çalışma kapsamındaki tarih aralığında ilgilenilen havayolunun ve rakiplerinin IST-DUS hattındaki uçuşları Şekil 3.3’de gösterilmiştir.




Şekil 3.3: Havayolu ve üç rakibi tarafından IST'den DUS'a uçulan günler.

3.2.YÖNTEM

İş açısından daha iyi bir model oluşturmak için, üretilecek modeli en yüksek kârlı satış verileriyle eğitmek için gözlem verileri ikiye bölünmüştür. Örneğin, her ay için Pazartesi uçuşları alınmış, sıralanmış ve karşılaştırılmıştır. En iyi iki hafta (veya üçüncü en iyi hafta kar rakamı dördüncü yerine ikinci haftaya daha yakınsa üç hafta) değerlendirilmiştir. Bu işlem gözlem verilerinin olduğu haftanın her günü ve yılın her ayı için yapılmıştır. Modelleri eğitmek ve test etmek için daha az gözlem verisi kalmış olsa da amaç daha iyi bir fiyat teklifiyle daha iyi bir karar destek sistemi üretmektir. Bölünmüş veriler 12.575 gözleminden oluşmaktadır. Daha sonra veriler aykırı değerlerden filtrelenmiş ve yuvarlatılmıştır. Her bir aşamanın sonucunda ulaşılan veri seti korunmuştur. Elde edilen veri setleri çeşitli modellere ve yeni geliştirilen bir

modele uygulanmıştır. Uygulamaların çıktıları altı farklı istatistiki performans kriterlerine göre değerlendirilmiştir. Yeni geliştirilen modelin diğer modellere göre daha sonuçlar ürettiği tespit ettiği sonucuna ulaşılmıştır. Bu sonuçlar ile örnek fiyat teklifi aralığına ulaşılmış ve grafiksel olarak gösterilmiştir. Yapılan bu çalışmanın akış diyagramı Şekil 3.4’de gösterilmiştir.



Şekil 3.4: Bu çalışmanın akış diyagramı.

3.3.ÖN İŞLEME


Alekseev ve Seixas (2009), zaman serilerinde aykırı değerlerin (noise) varlığını belirtir ve serinin modelini bulmayı zorlaştıranın da bu aykırı değerlerin olduğunu ifade ederler. Genellikle seri analiz tekniği, tasarımı daha belirgin hale getirmek için aykırı değerleri filtrelemek için bir form içerir (Hill ve diğ., 1996).

Gelir yöneticilerine sunulacak fiyat tahmin aralığını daraltabilmek için aykırı fiyatlamalar belirlenir. Bir bilet fiyatının aykırı olmasının farklı nedenleri vardır. Küresel Dağıtım Sistemi (GDS) satışları ve grup satışları bu tür satışlara örnektir. 20 Haziran 2017 uçuş tarihi için örnek bir veri Tablo 3.1'de verilmiştir.

Tablo 3.1: 20 Haziran 2017 uçuş tarihi için örnek bir gözlem verisi.

Haftanın Günü	Yılın Haftası	Uçuşa Kalan Gün	Sınıf	Boş Koltuk Kapasitesi	Fiyat	CASK Değeri	Hedef Gelir	Tatil mi?	THY Fiyatı	Atlas Fiyatı	Pegasus Fiyatı
3	25	42	82	217	33.96	0.04	83	0	12.99	58	15.48
3	25	40	82	213	19.41	0.04	83	0	13.02	58	22.17
3	25	35	82	210	35.05	0.04	83	0	13.02	0	22.17
3	25	26	79	209	33.14	0.04	83	0	13.12	58	22.34
3	25	25	79	208	32.00	0.04	83	0	13.12	58	22.34
3	25	22	79	206	23.74	0.04	83	0	13.12	58	22.34
3	25	21	79	200	32.43	0.04	83	0	13.12	58	22.34
3	25	19	79	197	32.23	0.04	83	0	12.98	58	21.20
3	25	18	79	195	32.90	0.04	83	0	12.98	58	21.20
3	25	17	79	191	38.25	0.04	83	0	12.98	58	21.20
3	25	14	79	184	46.15	0.04	83	0	0.00	0	0.00
3	25	12	79	183	37.38	0.04	83	0	14.00	58	23.13
3	25	11	79	181	32.83	0.04	83	0	14.00	58	23.13
3	25	10	88	174	41.91	0.04	83	0	14.00	58	23.13
3	25	10	79	168	21.99	0.04	83	0	14.00	58	23.13
3	25	9	82	165	18.89	0.04	83	0	14.00	58	23.13
3	25	8	88	163	41.56	0.04	83	0	14.00	58	23.13
3	25	8	82	160	22.20	0.04	83	0	14.00	58	23.13
3	25	7	82	157	24.81	0.04	83	0	14.00	58	23.13
3	25	6	82	147	20.09	0.04	83	0	14.05	58	23.27
3	25	6	79	135	40.92	0.04	83	0	14.05	58	23.27
3	25	5	82	134	20.71	0.04	83	0	14.05	58	23.27
3	25	4	79	129	37.56	0.04	83	0	14.05	58	23.27
3	25	3	79	124	31.89	0.04	83	0	14.05	58	23.27
3	25	2	82	116	27.44	0.04	83	0	14.05	58	23.27
3	25	1	82	109	25.10	0.04	83	0	14.05	58	23.27
3	25	1	79	108	34.14	0.04	83	0	14.05	58	23.27
3	25	1	88	106	46.37	0.04	83	0	14.05	58	23.27
3	25	0	88	87	38.15	0.04	83	0	14.05	58	23.27

Çalışma için Dataset20 ve Dataset10 adlı iki yeni veri seti hazırlanmıştır. Dataset20, trend çizgisine olan fiyat farkının değerinin yüzde 20'sinden az olduğu gözlemdir. Dataset10, trend çizgisine olan fiyat farkının değerinin yüzde 20'sinden az olduğu gözlemdir. Verilen ay için, Şekil 3.5'de olduğu gibi, Veri Kümesi20'yi elde etmek için kırmızı noktalar Raw'dan çıkarılır ve Veri Kümesi10'u elde etmek için yeşil noktalar Veri Kümesi20'den çıkarılır. İki yeni veri kümesinde sırasıyla 10.684 ve 7.294 gözlem bulunmaktadır.



Şekil 3.5: Aykırı değerler grafiği.

Verilerdeki yüksek dalgalanmalar, hareket tarihine kadar koltuk ve fiyat yönetiminin zorluğunu kanıtlamaktadır. Öznelliği azaltmak için eğilim, verileri yuvarlayarak incelenmiştir. Düzeltme, bir veri hazırlama tekniği olarak kullanışlıdır. Gözlemlerdeki rastgele değişimi azaltmak, dalgalanmayı azaltmak ve aykırı değerleri azaltmak için kullanılır, böylece temeldeki nedensel süreçlerin yapısını daha iyi ortaya çıkarabilmek mümkündür. Hareketli ortalama, orijinal veri kümesinin düzgünleştirilmiş bir versiyonunu oluşturmak için bir veri hazırlama tekniği olarak kullanılır.

Düzeltmeyi seriye uygulamadan önce, verilerin durağan olup olmadığını kontrol etmek için Augmented Dickey-Fuller (birim kök) testi uygulanmıştır. Etienne (2019) durağanlığı ortalama,

varyans ve otokorelasyon gibi sabit istatistiksel özellikler sergileme özelliği olarak tanımlar. Zaman serileri analizinde birim kökler varsa tahmin edilemeyen sonuçlar elde edilebilir. Tablo 3.2, her iki veri setinin sonuçlarını göstermektedir. P değeri, belirtilen anlamlılık düzeyinden (0.01) düşük olduğu için, sıfır hipotezi (null hypothesis) reddedilebilir.

Tablo 3.2: Augmented Dickey-Fuller tek kök (unit root) test.

	Ham Data	Aykırı Değerler olmadan
ADF Statistic:	-3.496144	-3.523462
p-value:	0.008087	0.007405
Critical Values:		
1%:	-3.431	-3.431
5%:	-2.862	-2.862
10%:	-2.567	-2.567


5 pencere boyutu ile Yerel Ağırlıklı Yuvarlama (Loess) kullanılmıştır, yani bir (t) anında dönüştürülen değer önceki beş gözlem için ortalama değer olarak hesaplanmıştır. Yuvarlanmış fiyat değerlerine sahip veri kümesine, bu belgenin geri kalanı için Smoothed adı verilmiştir.

Son olarak veri kümeleri, %80 eğitim, %10 doğrulama ve %10 test olarak bölümlendirilmiştir. Bu işlemlerin sonucunda elde edilen veri kümeleri ve bölümlmeleri Şekil 3.6 da gösterilmiştir.

Farkı açıkça göstermek için, ham ve yuvarlatılmış verilerin son 400 tahmini sırasıyla Şekil 3.7 ve 3.8'de gösterilmektedir.




Şekil 3.6: Veri kümeleri ve bölümlmeleri.



Gerçek ve Tahmini Gözlem Verileri

Şekil 3.7: Ham verilerle son 400 tahmin.



Gerçek ve Tahmini Gözlem Verileri

Şekil 3.8: Yuvarlatılmış verilerle son 400 tahmin.

3.4.ARAÇLAR

Bu çalışmada Tableau, Spyder Python ve colab ortamları kullanılmıştır. COLAB, makine öğrenimiyle ilgili eğitim ve araştırmanın yaygınlaştırılmasına yardımcı olmak için oluşturulmuş bir Google araştırma projesidir. Popüler kitaplıkları kullanan bir Jupyter dizüstü ortamıdır. Bu araştırma sırasında kullanılan kütüphaneler Tablo 3.3'te listelenmiştir.

Tablo 3.3: Kullanılan kütüphaneler.

Paket	Versiyon	Paket	Versiyon	Paket	Versiyon
python	3.6.9	statsmodels	0.10.2	python	3.7.3
tensorflow	2.3.0	seaborn	0.11.0	IPython	7.6.1
torch	1.7.0+cu101	tqdm	4.41.1		
pandas	1.1.4	keras	2.4.3		
numpy	1.18.5	livelossplot	0.5.3		
matplotlib	3.2.2	xgboost	0.90		
sklearn	0.22.2. post1				

3.5.MODELLER

Bu araştırma sırasında aşağıda listelenen makine öğrenme modelleri kullanılmıştır.

ARIMA: ARIMA'nın AR kısmı, ilgilenilen değişen değişkenin kendi gecikmeli (lagged) değerlerine göre gerilediğini gösterir. MA bölümü, regresyon hatasının, değerleri eşzamanlı olarak ve geçmişte çeşitli zamanlarda oluşan hata terimlerinin doğrusal bir kombinasyonu olduğunu gösterir. I ("entegre" için), veri değerlerinin, değerleri ve önceki değerler arasındaki farkla değiştirildiğini (ve bu farklılaştırma işleminin birden fazla kez gerçekleştirilmiş olabileceğini) gösterir. Bu özelliklerin her birinin amacı, modelin mümkün olduğu kadar verilere uymasını sağlamaktır (Oto-regresif entegre hareketli ortalama, 2020).

Rastgele Ormanlar: Rastgele ormanlar, her ağacın ormandaki tüm ağaçlar için aynı dağılıma sahip bağımsız olarak örneklenen rastgele bir vektörün değerlerine bağlı olacağı şekilde ağaç yordayıcılarının bir kombinasyonudur (Breiman, 2001).

Extreme Gradient Boosting: Boosting, eğitim verilerinin yeniden ağırlıklandırılmış sürümlerine sırayla bir sınıflandırma algoritması uygulayarak ve ardından bu şekilde üretilen sınıflandırıcı dizisinin ağırlıklı çoğunluk oyunu olarak çalışır. (Friedman ve diğ., 2000).

DNN: Bir Derin Sinir Ağı, nöronların önceki katmandan gelen nöron aktivasyonlarını girdi olarak aldığı ve basit bir hesaplama yaptığı (örneğin, doğrusal olmayan bir aktivasyonun takip ettiği girdinin ağırlıklı toplamı) birden fazla katman dizisi halinde organize edilmiş bir nöronlar topluluğudur (Montavon ve diğ., 2018).

CNN: Hücresel Sinir Ağı, birbirleriyle yalnızca en yakın komşuları aracılığıyla doğrudan iletişim kuran, hücreler olarak adlandırılan, düzenli aralıklarla yerleştirilmiş devre klonlarının büyük bir kümesinden oluşur (Chua ve diğ. 1988).

IMV-LSTM: Doğrusal olmayan sıralı verileri işlemedeki başarısı ile uzun vadeli ve kısa vadeli bağımlılık sorunlarını çözme konusunda güçlü bir yeteneğe sahip olan belirli bir RNN türü olan Uzun Kısa Süreli Bellek sinir ağı, yalnızca bitişik anlık bilgileri saklayamaz ama aynı zamanda uzun vadeli ayrıntıları da kontrol eder. LSTM sinir ağının çekirdeği, geleneksel nöronların gizli katmanlarının yerini alan bellek hücresidir (Li, Wu ve Liu, 2018). LSTM modeli, Hochreiter & Schmidhuber (1997) tarafından tanıtıldı ve birimi bir hücre, bir giriş kapısı, bir çıkış kapısı ve bir unutma kapısından oluşur.

$$\text{input gate's activation vector: } i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (3.1)$$

$$\text{output gate's activation vector: } o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (3.2)$$

$$\text{forget gate's activation vector: } f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3.3)$$

$$\text{cell input activation vector: } \tilde{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \quad (3.4)$$

$$\text{cell state vector: } c_t = f_t * c_{t-1} + i_t * \tilde{c}_t \quad (3.5)$$

$$\text{hidden state vector: } h_t = o_t * \tanh(c_t) \quad (3.6)$$

IMV-LSTM fikri, gizli durum (hidden) matrisini kullanmak ve gizli matrisin her bir ögesinin (örneğin satır) yalnızca girdinin belirli bir değişkeninden gelen bilgileri kapsadığı şekilde ilişkili güncelleme şeması geliştirmektir (Guo ve diğ., 2019).

$$\text{the hidden state update: } \tilde{j}_t = \tanh(W_j \odot \tilde{h}_{t-1} + U_j \odot x_t + b_j) \quad (3.7)$$

$$\text{gate vectors: } \begin{bmatrix} i_t \\ f_t \\ o_t \end{bmatrix} = \sigma(W [x_t \oplus \text{vec}(\tilde{h}_{t-1})] + b) \quad (3.8)$$

$$\text{cell state vector: } c_t = f_t \odot c_{t-1} + i_t \odot \text{vec}(\tilde{j}_t) \quad (3.9)$$

$$\text{hidden state vector: } \tilde{h}_t = \text{matricization}(o_t \odot \tanh(c_t)) \quad (3.10)$$

burada $\oplus$ birleştirme işlemi ve $\odot$ ise eleman bazlı çarpma işlemidir.


Modeller tarafından kullanılan hiper parametrelerden biri yığıt (batch) boyutudur. Yığıt boyutu, ağın öğrenme sürecinde eğitilmesi için kullanılacak olan eğitim örneğinin alt küme boyutunu (örneğin 1000'de 256) belirtir. Her yığıt, bir önceki yığıtın uygulanmasından gelen güncellenmiş ağırlıkları göz önünde bulundurarak, ağı art arda eğitir.

Geleneksel algoritmalarındaki yığıt boyutu sabit tutulmuştur. Uçuş tarihinin ve satış modellerinin doğası gereği, değişken bir yığıt boyutu yaklaşımı geliştirilmiş ve uygulanmıştır. Belirli bir uçuşa yapılan tüm satışlar tek bir yığıt olarak kabul edilmiştir. Satış tarihlerinin sayısı birbirinden farklı olduğu için yığıt büyüklüğünün kendisi de değişecektir. Geriye bakma (look back) ayarı, regresörlerin değerleri ve yeni uçuş için hedef değer sıfırlandığından, birbirinden bağımsız her bir yığıt için yapılır. Bu sıfırlama, verilerin bir uçuşun satış tarihi sayısı ile çakışan pencerelerle günlük zaman serileri olmasına neden olur. Grupların örtüşen pencereler kavramı olarak değerlendirilmesi Şekil 3.9'da gösterilmektedir. Verilerin geri bakma süresi yeşil renktedir ve boyutu deneylerden sonra ayarlanabilir.


Bu yeni yaklaşıma Varyant Yığıt Boyutu IMV-LSTM (Variant Batch Size IMV-LSTM) olarak adlandırılmıştır. Ayarlanan yığıtlar, Şekil 3.10'da gösterildiği gibi VBS IMV-LSTM modelinde kullanılmıştır.

3.6.İSTATİSTİKİ PERFORMANS KRİTERLERİ

Önceki çalışmalar incelenmiş ve geliştirilen modelleri değerlendirmek için istatistiksel değerlendirme kriterleri kullanılmıştır.



Şekil 3.9: Veri yığıtlarının (batch) ayarlanması.



Şekil 3.10: Her yığıtın kendi uzunluğu ve geriye bak kaydırması vardır.

Bu kriterler, aşağıdaki denklemlerle verilen RMSE (Root Mean Square Error), a10-endeksi, a20-endeksi, RMSPE (Root Mean Square Percentage Error) ve Doğruluktan (Accuracy) oluşur:

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{n}} \quad (3.11)$$

$$a10\text{-index} = \frac{m10}{M} \quad (3.12)$$

$$a20\text{-index} = \frac{m20}{M} \quad (3.13)$$

$$R^2 = 1 - \frac{\sum (y_i - \hat{y})^2}{\sum (y_i - \bar{y})^2} \quad (3.14)$$

$$RMSP E = \sqrt{\frac{1}{n} \sum_{i=1}^n \frac{(\hat{y}_i - y_i)^2}{y_i}} 100\% \quad (3.15)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (3.16)$$

$$\text{Accuracy} = 100 - 100 * MAPE \quad (3.17)$$

burada $\hat{y}_i$ tahmin edilen değerlerdir, y_i gözlemlenen değerlerdir; $\bar{y}$, y değerlerinin ortalamasıdır ve n gözlem sayısıdır. M veri seti örnek sayısı, $m10$ deneysel hız değeri/tahmin değeri 0.90 ile 1.10 arasında olan örnek sayısı ve $m20$ deneysel hız değeri/tahmin değeri değeri 0.80 ile 1.20 arasında olan örnek sayısıdır.

4. BULGULAR

Yukarıda ifade edilen modellerin çalıştırılabilmesi için Central Processing Unit – Merkezi İşlem Ünitesi (CPU) tabanlı bilgisayarlar yerine Graphics Processing Unit – Grafik İşleme Ünitesi (GPU) bazlı bilgisayarlar kullanılmıştır. Bu tür bilgisayarlar maliyetli olabileceğinden Google firması bu tür araştırmaların yapılabileceği ücretsiz ortam sağlamaktadır. Bu ortama COLAB adı verilmiştir ve python türü uygulamalar çalıştırılabileceği gibi, GPU tabanlı uygulamalar çalıştırabilmek de mümkündür. Yapılan denemelerde örneğin CPU tabanlı bir bilgisayarda yaklaşık 4 saat kadar süren bir uygulamanın GPU tabanlı bir bilgisayarda yaklaşık 20 dakika içinde sonuç üretebildiği ölçülmüştür.

COLAB ortamı GPU bazlı denemeler yapılmak istendiğinde maalesef aynı anda sadece iki uygulamanın çalıştırılabilmesini izin vermektedir. Bu sorunu aşabilmek için farklı hesap adları ile aynı dizin yapısı kullanılarak denemeler yapmak mümkündür. Farklı hesap adları kullanıldığında kullanılan program versiyonlarına ve dizin yapılarına ayrıca dikkat etmek gerekmektedir.

Bu araştırma boyunca kullanılan COLAB ortamının ve geliştirilen model ile yaklaşımın (VBS IMV-LSTM) özellikleri (hiperparametre değerleri) ve geri bakma zamanı adımı için en iyi değerler Tablo 4.1'de sunulmuştur.

Tüm veri kümeleri (Ham, Dataset20, Dataset10, Smoothed) için eğitim aşamalarının, doğrulama aşamalarının ve test aşamalarının önerilen model regresyon katsayısı sayısal değerleri Şekil 4.1'de ve çıktı hesaplama formülleri Tablo 4.2'de verilmiştir.

Tablo 4.1: VBS IMV-LSTM hiperparametre ayarları.

a) COLAB		b) Geri Bakma zaman adım sayısı.	
Hyperparametre	Ayarlanan Değer	Veri Seti	Zaman Adım Sayısı
Tabaka Sayısı	1	Raw	2
Hücre Sayısı	256	Dataset20	2
İleriye dönük vade	1	Dataset10	1
Learning Rate	0.001	Smoothed	2
Gamma	0.9		
Epochs	500		
Patience	30		
Adım Sayısı	20		
Yığıt Uzunluğu	Dinamik (Satış gün sayısı)		

Tablo 4.2: VBS IMV-LSTM'de çıktı hesaplama formülleri.

Bölümler	Formüller			
	Ham	Dataset20	Dataset10	Smoothed
Eğitim	$0.92 * \text{Target} + 11.56$	$0.96 * \text{Target} + 6.27$	$0.97 * \text{Target} + 4.14$	$0.99 * \text{Target} + 0.53$
Doğrulama	$0.97 * \text{Target} + 12.33$	$1.06 * \text{Target} - 3.96$	$1.07 * \text{Target} - 5.57$	$1.02 * \text{Target} - 0.26$
Test	$0.95 * \text{Target} + 6.29$	$1.01 * \text{Target} + 2.45$	$1.06 * \text{Target} - 2.60$	$1.02 * \text{Target} - 0.94$


Şekil 4.1’de görüleceği üzere veri setindeki aykırı değerler filtrelendiğinde hesaplanan hedef değer ile gerçek değer arasındaki fark azalmaktadır; modeller gerçek değere daha yakın tahmini değerler üretebilmektedir. Bu sonuçlar veri kalitesinin model performansını nasıl etkilediği konusunda da veri üretmektedir.

Ampirik analiz, modellerin farklı veri setlerine göre farklı performanslar verdiğini ortaya koymaktadır. Bu çalışmada kullanılan modeller 3.5 Modeller kısmında açıklanmıştır. Seçilen modeller sadece Yapay Sinir Ağları ile sınırlı kalmaması için diğer model tiplerinden örneklerle de çalışılmıştır. Elde edilen en iyi sonuçlar Tablo 4.3’de verilmiştir ve en başarılı sonuçlar kalın yazılmıştır.

Model performanslarını değerlendirebilmek için altı farklı kriter kullanılmıştır. Bu kriterlerin açıklamaları 3.6 İstatistiki Performans Kriterleri kısmında formülleriyle açıklanmıştır. Literatürde birçok kriterin uygulandığı görülmektedir. En yaygın olarak kullanılan ile son zamanlarda daha çok kullanıldığı gözlemlenen a10-index ve a20-index kriterleri de bu çalışmaya dahil edilmiştir.

Empirik çalışmalar boyunca farklı geriye bakış (look-back) değerleriyle çalışılmıştır. En iyi performansların birden dörde kadar olan değerlerde alındığı belirlenmiştir. Tablo 4.3’de elde edilen değerler geriye bakış değeri dörde kadar olan denemelerde en iyi sonucun ürettiği değerlerdir.

COLAB ortamı dışında yapılan değerler (Örneğin codeocean, anaconda ve spider) veya farklı çekirdek (seed) değeri ile yapılan denemeler Tablo 4.3 de üretilen değerlere bazı farklılıklar gösterse de performans farklarının görüldüğü gözlenmiştir.




Şekil 4.1: VBS IMV-LSTM Regresyon katsayısı sayısal değerleri.

Tablo 4.3: Ampirik analiz.

Data	Model	RMSE	a10-index	a20-index	R ²	RMSPE (%)	Accuracy (%)
Ham	ARIMA	26.21	0.41	0.69	0.71	109.19	28.15
	Random Forests	23.01	0.42	0.70	0.74	33.27	78.83
	Extreme Gradient Boosting	21.67	0.44	0.70	0.76	34.15	79.83
	DNN	35.72	0.19	0.39	0.68	26.56	77.14
	CNN	34.74	0.20	0.40	0.69	32.56	75.34
	IMV-LSTM	25.75	0.40	0.66	0.67	37.53	77.59
	VBS IMV-LSTM	21.97	0.43	0.71	0.82	25.50	82.76
Dataset20	ARIMA	23.29	0.49	0.81	0.77	89.74	39.44
	Random Forests	23.12	0.46	0.73	0.75	27.31	81.78
	Extreme Gradient Boosting	19.84	0.45	0.75	0.78	23.90	83.84
	DNN	32.62	0.20	0.42	0.72	27.14	76.87
	CNN	33.37	0.20	0.42	0.71	29.19	77.57
	IMV-LSTM	22.15	0.52	0.79	0.77	26.16	85.22
	VBS IMV-LSTM	18.80	0.54	0.81	0.87	16.04	88.05
Dataset10	ARIMA	23.79	0.65	0.88	0.74	89.29	41.25
	Random Forests	24.49	0.51	0.78	0.74	25.39	83.87
	Extreme Gradient Boosting	20.08	0.48	0.76	0.79	19.32	86.47
	DNN	32.37	0.18	0.33	0.73	32.19	73.06
	CNN	32.94	0.24	0.45	0.72	32.08	77.46
	IMV-LSTM	22.67	0.62	0.87	0.75	27.73	87.31
	VBS IMV-LSTM	15.41	0.68	0.90	0.91	12.93	90.74
Smoothed	ARIMA	5.88	0.92	0.99	0.98	77.39	47.73
	Random Forests	38.54	0.30	0.56	0.42	42.14	72.26
	Extreme Gradient Boosting	28.85	0.32	0.60	0.53	31.44	78.33
	DNN	41.02	0.15	0.31	0.52	32.18	72.95
	CNN	25.62	0.24	0.45	0.81	20.95	81.70
	IMV-LSTM	5.94	0.90	0.99	0.98	6.54	95.88
	VBS IMV-LSTM	5.32	0.95	0.99	0.99	5.57	96.25

COLAB ücretsiz bir ortam sunmasına rağmen GPU tabanlı bir uygulama çalıştırılmak istendiğinde belirli bir kota uygulamaktadır. Bu durum, dar bir zaman aralığında fazla sayıda deneme yapma ihtiyacına engel olmaktadır. Ancak farklı gmail hesabı ile aynı kullanıcı denemelerine devam edebilmekte, söz konusu kota problemini birden fazla hesap kullanarak aşabilmektedir.

Düzgünleştirilmiş veri kümesi için VBS IMV-LSTM'nin ısı haritası sonucu Şekil 4.2'de gösterilmektedir. Önerilen CASK ve Hedef Gelir özelliklerinin katkısı haritadan görülebilir. Isı haritasına göre en etkili regresörün bir önceki gün belirlenen bilet fiyatı olduğu görülmektedir. Bunun yanında uçuşa kalan gün sayısı ile rakip firmanın bilet fiyatının da etkili olduğu görülmektedir. En iyi performans verileri geri bakış değerinin iki olduğu durumda elde edildiği için ısı haritası buna göre üretilmiştir.



Şekil 4.2: Veri kümesi Smoothed için zaman adımı 2'ye göre VBS IMB-LSTM'nin ısı haritası.

Ayrıca en iyi değerleri üretmiş olan IMV-LSTM model ile bu çalışmada sunulan VBS IMV-LSTM modelleri farklı geri bakış zaman adımları için de karşılaştırılmıştır. Bu karşılaştırmanın sonuçları Tablo 4.4'de sunulmuştur. Bu tabloda örtüşen pencere yapısındaki veri setlerinde batch size değerlerinin dinamik olarak her pencere için kendi uzunluğu olarak belirlenmesinin, batch size değerinin sabit bir değer olarak tutulmasına göre daha iyi tahminleme yaptığını görmek mümkündür.

Bu denemelerde her bir model için kullanılan kaynak kodları Ekler bölümünde (Ek.1-7) gösterilmiştir. Yukarıda da ifade edildiği üzere bu çalışmada, denemeler süresince kullanılan modellerin yazılımında Python programlama dili kullanılmıştır. Bu kaynak kodlarında kullanılan dizin yapıları denemelerin yapıldığı COLAB ortamına göre gösterilmiştir. Farklı ortamlarda denemeler yapılmak istendiğinde ilgili dizin yapılarının yeni ortamdaki kullanıma göre tekrar düzenlenmesi gerekmektedir. Ayrıca hiper parametreleri de değiştirerek farklı denemeler yapılabilir.

Tablo 4.4'de IMV-LSTM modeli için kullanılan statik batch size değeri 40 olarak kullanılmıştır. Filtrelenmemiş Ham veri seti için uygulanan dinamik modelde ortalama batch size 42'dir. Bu değerin farklı kullanılması sonuca olumlu etki oluşturabileceği düşünülmüştür. Dinamik model için kullanılan değişken batch size uygulamasında, Smoothed veri kümesi için batch size

ortalaması 21.84'tür. Statik ile dinamik modelin performansını daha yakından karşılaştırmak için farklı batch size değerleri ile statik model ve dinamik modeller üzerinde denemeler yapılmıştır. Bu denemelerin karşılaştırması Tablo 4.5'de sunulmuştur.

Şekil 4.3, son 30 gözlem için uygulanan eşikler ile elde edilen sonuçları göstermektedir. Noktalı çizgi fiili fiyat teklifleridir, kırmızı koridor ham verilerle elde edilmiştir, açık yeşil koridor filtrelenmiş verilerle elde edilmiştir ve son olarak yeşil koridor yumuşatılmış verilerle elde edilmiştir. Filtrelenmiş verilerle elde edilen koridorun gerçek fiyat tekliflerini en iyi kapsadığı görülmektedir. Yeşil koridor, gelecekteki fiyat ayarları için dikkate alınacak piyasa trendi için düşünülebilir.



Tablo 4.4: IMV-LSTM ve VBS IMV-LSTM ile çeşitli zaman aralıklarıyla deneyler.

Dataset: Raw														
IMV-LSTM								VBS IMV-LSTM						
Time Step	MSE	RMSE	a10 index	a20 index	R ²	RMSPE	Accuracy	MSE	RMSE	a10 index	a20 index	R ²	RMSPE	Accuracy
$t-1$	751.72	27.42	0.37	0.62	0.63	39.28	76.35	638.19	25.26	0.41	0.65	0.80	27.93	80.78
$t-2$	684.07	26.15	0.41	0.67	0.71	36.55	78.07	482.75	21.97	0.43	0.71	0.82	25.50	82.76
$t-3$	662.88	25.75	0.40	0.66	0.67	37.53	77.59	542.50	23.29	0.45	0.69	0.81	26.83	82.24
$t-4$	684.18	26.16	0.41	0.67	0.69	35.72	78.65	586.27	24.21	0.42	0.69	0.80	28.63	81.16


Dataset: Dataset20														
IMV-LSTM								VBS IMV-LSTM						
Time Step	MSE	RMSE	a10 index	a20 index	R ²	RMSPE	Accuracy	MSE	RMSE	a10 index	a20 index	R ²	RMSPE	Accuracy
$t-1$	602.26	24.54	0.49	0.75	0.76	28.19	83.42	369.34	19.22	0.53	0.80	0.87	16.53	87.50
$t-2$	536.33	23.16	0.51	0.79	0.78	26.31	84.89	353.60	18.80	0.54	0.81	0.87	16.04	88.05
$t-3$	490.46	22.15	0.52	0.79	0.77	26.16	85.22	394.44	19.86	0.52	0.80	0.86	17.06	87.33
$t-4$	507.65	22.53	0.50	0.80	0.77	27.07	85.28	412.02	20.30	0.52	0.79	0.85	17.65	86.95

Dataset: Dataset10														
IMV-LSTM								VBS IMV-LSTM						
Time Step	MSE	RMSE	a10 index	a20 index	R ²	RMSPE	Accuracy	MSE	RMSE	a10 index	a20 index	R ²	RMSPE	Accuracy
$t-1$	552.59	23.51	0.60	0.86	0.78	27.24	86.74	237.34	15.41	0.68	0.90	0.91	12.93	90.74
$t-2$	555.21	23.56	0.62	0.83	0.76	28.62	86.63	291.69	17.08	0.63	0.87	0.89	14.43	89.54
$t-3$	514.00	22.67	0.62	0.87	0.75	27.73	87.31	272.99	16.52	0.65	0.97	0.89	13.99	89.81
$t-4$	546.41	23.38	0.59	0.83	0.74	30.56	85.77	367.80	19.18	0.42	0.81	0.84	16.99	86.59

Dataset: Smoothed														
IMV-LSTM								VBS IMV-LSTM						
Time Step	MSE	RMSE	a10 index	a20 index	R ²	RMSPE	Accuracy	MSE	RMSE	a10 index	a20 index	R ²	RMSPE	Accuracy
$t-1$	99.22	9.96	0.78	0.94	0.95	10.31	92.87	80.17	8.95	0.82	0.97	0.96	8.40	93.89
$t-2$	88.60	9.41	0.82	0.96	0.95	8.99	93.75	28.25	5.32	0.95	0.99	0.99	5.57	96.25
$t-3$	72.48	8.51	0.80	0.94	0.96	10.02	93.38	35.41	5.95	0.93	0.99	0.98	6.69	95.83
$t-4$	35.32	5.94	0.90	0.99	0.98	6.54	95.88	33.58	5.79	0.93	0.99	0.98	5.69	96.05

Tablo 4.5: IMV-LSTM ve VBS IMV-LSTM ile çeşitli batch size değerleri ile deneyler.

Look back	Batch Size	mse	a10-index	a20-index	R ²	RMSPE	Accuracy
<i>t-1</i>	10	114.93	0.73	0.89	0.94	12.57	91.48
	20	91.29	0.81	0.97	0.96	8.82	93.74
	30	88.61	0.82	0.96	0.95	8.99	93.75
	40	99.22	0.78	0.94	0.95	10.31	92.87
	50	114.38	0.75	0.93	0.94	11.25	92.16
	Dinamik	80.17	0.82	0.97	0.96	8.40	93.89
<i>t-2</i>	10	33.57	0.92	0.99	0.98	6.45	96.05
	20	43.23	0.90	0.98	0.98	7.08	95.43
	30	56.99	0.86	0.95	0.97	8.79	94.26
	40	88.60	0.82	0.96	0.95	8.99	93.75
	50	84.78	0.80	0.95	0.96	10.27	92.74
	Dinamik	28.25	0.95	0.99	0.99	5.57	96.25
<i>t-3</i>	10	36.55	0.92	0.99	0.98	6.37	95.80
	20	46.02	0.89	0.97	0.98	7.60	94.84
	30	58.17	0.84	0.95	0.97	9.20	93.77
	40	72.48	0.80	0.94	0.96	10.47	92.96
	50	68.90	0.83	0.94	0.96	10.02	93.38
	Dinamik	35.41	0.93	0.99	0.98	6.29	95.83
<i>t-4</i>	10	38.79	0.91	0.99	0.98	6.15	95.89
	20	35.98	0.92	0.99	0.98	6.08	95.89
	30	42.18	0.89	0.98	0.98	7.39	95.25
	40	35.32	0.90	0.99	0.98	6.54	95.88
	50	60.73	0.83	0.95	0.97	9.45	93.58
	Dinamik	33.58	0.93	0.99	0.98	5.69	96.05



Şekil 4.3: Elde edilen fiyat koridorları ve gerçek değerler.

5. TARTIŞMA VE SONUÇ

Bu çalışmada, bir havayolunun gelir yönetimi ve karar destek sistemi olarak bilet fiyatlandırma atamasında Makine Öğrenimi modellerinin nasıl uygulanabileceği araştırılmıştır. İstanbul, Türkiye merkezli düşük maliyetli bir havayolunun gerçek verileri ve rakiplerinin bilet fiyatları kullanılmıştır. İSTANBUL- DÜSSELDORF güzergahı çalışılmıştır ve sadece tek yön bilet fiyatları dikkate alınmıştır. Literatürdeki diğer çalışmalardan farklı olarak Kullanılabilir Koltuk Kilometresi Başına Maliyet (CASK) ve Hedef Gelir özellikleri de yer almaktadır. Geleneksel ve yakın zamanda önerilen Makine Öğrenimi modelleri araştırılmış ve karşılaştırılmıştır. Geleneksel yaklaşımlar düşük istatistiksel kriter puanları vermektedir. Diğerlerinden daha iyi performans gösteren modele yeni bir yaklaşım önerilmektedir. Gözlem verileri, en karlı bilet fiyatını tahmin etmek için eğitilecek ve test edilecek modeller için ikiye ayrıştırılmıştır.

Hedef değer önemli ölçüde insan yargılarına bağlı olduğundan, gelir yöneticilerine sunulacak bir fiyat aralığının öngörülmesi amaçlanmıştır. Fiyatın yapısını daha iyi ortaya çıkarmak için en yüksek kârlı ham satış verileri kullanılmıştır, aykırı değerler süzölmüş ve ardından kalan veriler düzeltilmiştir. Veri özellikleri hedef değer ile daha tutarlı hale getirilmiştir ve her aşamadaki ampirik çalışmalar öncekilere göre daha iyi sonuçlar üretmiştir. Sunulan modelimiz geleneksel modellerden daha iyi sonuçlar üretmiştir.

Fiyat dalgalanmaları azaldıkça ve satış grafiği durağanlaştıkça önerilen modelin istatistiksel performansı artmaktadır. Bu fiyat tekliflerinin ve trendin bir karar destek sistemi olarak kullanılmasıyla, öznellik ve panik fiyat atanmasının azaltılabileceğine ve daha iyi yönetim sağlanabileceğine inanıyoruz. Ayrıca, azaltılmış öznel verilerin toplanmasıyla, model zamanla daha az hatalı yüzdeleri tahmin etmek için daha iyi eğitilebilir.

Bu çalışmada, veri sağlayıcı firmadan rakiplerin haftalık minimum fiyatları toplanmıştır. Bununla birlikte, günlük minimum verilerin kullanılması daha iyi sonuçlar verecektir.

Bilet fiyatı tahsisi konusunda insan yargısının azaltılması, eksik verilerin ve günlük verilerin kullanımının önlenmesi, model performansını artıracak ve fiyat teklif aralığı zamanla daralacaktır. Gelecekteki çalışma, çalışmayı bir fiyat aralığı yerine bir fiyat sunacak şekilde optimize etmek olacaktır. Dinamik yığıt boyutlandırma, Geçitli Tekrarlayan Birim (GRU) gibi diğer modellere uygulanacaktır.

Model, örtüşen pencere yapısı ile benzer tarihsel verilere sahip diğer iş senaryoları tarafından kullanılabilir. |



KAYNAKLAR

- Abdella, A., Zaki, N., ve Shuaib, K., 2019, Airline ticket price and demand prediction: A survey, *Journal of King Saud University – Computer and Information Sciences*, <https://doi.org/10.1016/j.jksuci.2019.02.001>.
- Alekseev, K.C.P., ve Seixas, J.M., 2019, A multivariate neural forecasting modeling for air transport – Preprocessed by reorganizing decomposition: A Brazilian application, *Journal of Air Transport Management*, (15), 212–216 <https://doi.org/10.1016/j.jairtraman.2008.08.008>.
- Altan, A., Karasu, S., ve Bekiros, S., 2019, Digital currency forecasting with chaotic meta-heuristic bio-inspired signal processing techniques, *Chaos, Solitons and Fractals*, (126) 325–336. <https://doi.org/10.1016/j.chaos.2019.07.011>.
- Altan, A., ve Karasu, S., 2020, Recognition of COVID-19 disease from X-ray images by hybrid model consisting of 2D curvelet transform, chaotic salp swarm algorithm and deep learning technique, *Chaos, Solitons and Fractals*, (140) 110071, <https://doi.org/10.1016/j.chaos.2020.110071>.
- Belobaba, P. P., 1987, Survey Paper—Airline Yield Management An Overview of Seat Inventory Control. *Transportation Science*, Volume 21 (2) : 63–73, <https://doi.org/10.1287/trsc.21.2.63>.
- Bernstein, F., ve Federgruen, A., 2003, Pricing and replenishment strategies in a distribution system with competing retailers. *Operations Research*, 51 (3) 409–426, <https://doi.org/10.1287/opre.51.3.409.14957>.
- Bernstein, F., ve Federgruen, A., 2005, Decentralized supply chains with competing retailers under demand uncertainty, *Management Science* 51 (1) 18–29, <https://doi.org/10.1287/mnsc.1040.0218>.
- Bichler, M., Lawrence, R.D., Kalagnanam, J., Lee, H.S., Katircioglu, K., Lin, G.Y., King, A.J., ve Lu, Y., 2002, Applications of flexible pricing in business-to-business electronic commerce, *IBM Systems Journal*, 41(2): 287–302, <https://doi.org/10.1147/sj.412.0170>.
- Biller, S., Chan, L.M.A., Simchi-Levi, D., ve Swann, J., 2005, Dynamic pricing and the direct-to-customer model in the automotive industry. *Electron Commerce Research* 5, 309–334, <https://doi.org/10.1007/s10660-005-6161-4>.
- Bowles, M., 2015, Machine Learning in Python: Essential Techniques for Predictive Analysis, *John Wiley & Sons Inc.*, ISBN: 978-1-11896174-2.

- Boyd, E.A., ve Bilegan, I.C., 2003, Revenue management and e-commerce. *Management Science*, 49 (10): 1363–1386.
- Breiman, L., 2001, Random Forests. *Machine Learning* 45 (1) pp. 5–32. <https://doi.org/10.1023/A:1010933404324>.
- Brons, M., Pels, E., Nijkamp, P., ve Rietveld, P., 2002, Price elasticities of demand for passenger air travel: a meta-analysis, *Journal of Air Transport Management*, 8, 165–175, [https://doi.org/10.1016/S0969-6997\(01\)00050-3](https://doi.org/10.1016/S0969-6997(01)00050-3).
- Brooks, C.H., Fay, R., Das, R., MacKie-Mason, J.K., Kephart, J.O., ve Durfee, E.H., 1999, Automated strategy searches in an electronic goods market: Learning and complex price schedules. In *Proc. First ACM Conf. on Electronic Commerce (EC-99)* (New York: ACM Press) p 31–40.
- Burger, B., Fuchs, M., 2005, Dynamic pricing — A future airline business model, *Journal of Revenue and Pricing Management* 4, 39–53, <https://doi.org/10.1057/palgrave.rpm.5170128>.
- Cao, X., Shen, H., Milito, R., ve Wirth, P., 2002, Internet pricing with a game theoretic approach: concepts and examples. *IEEE/ACM Trans. Networking*, 10(2): 208–216, April.
- Carvalho, A.X., ve Puttman, M.L., 2003, Dynamic pricing and reinforcement learning, url: gg.nwu.edu/academic/deptprog/meds-dep/or-seminars/puterman.pdf.
- Chawla, B., ve Kaur, M.C., 2017, Airfare Analysis And Prediction Using Data Mining And Machine Learning, *International Journal of Engineering Science Invention*, 6 (11), pp. 10-17.
- Chen, Y., Cao, J., Feng, S., ve Tan, Y., 2015, An ensemble learning based approach for building airfare forecast service, *2015 IEEE International Conference on Big Data*, Santa Clara, CA, pp. 964-969.
- Chen, Y., ve Farias, V.F., 2015, Robust Dynamic Pricing With Strategic Customers, *Proceedings of the Sixteenth ACM Conference on Economics and Computation*, ACM, New York, NY, USA, pp. 777–777.
- Chiou, Y.C., ve Liu, C.H., 2016, Advance purchase behaviors of air passengers. A continuous logit model, *Transportation Research Part E* (93), 474–484 <https://doi.org/10.1016/j.tre.2016.07.001>.
- Chua, L.O., ve Yang, L., 1988, Cellular neural networks: theory, *IEEE Transactions on Circuits and Systems*, Volume: 35, Issue: 10 <https://doi.org/10.1109/31.7600>.

- Chung, S.H., Ma, H.L., Hansen, M., ve Choi, T.M., 2020, Data science and analytics in aviation. *Transportation Research Part E*, 134, <https://doi.org/10.1016/j.tre.2020.101837>.
- Cook, S., 2014, *Opportunities for the Airline and Transport Sector*, Deloitte, <https://www2.deloitte.com/content/dam/Deloitte/au/Documents/consumer-business/deloitte-au-cb-have-you-flown-off-course-with-your-approach-revenue-management-220914.pdf>, [Ziyaret tarihi: 17 Eylül 2020].
- Coy, P., 2000, The power of smart pricing, *Business Week*, April 10.
- Dasgupta, P., ve Das, R., 2000, Dynamic pricing with limited competitor information in a multi-agent economy. *Conference on Cooperative Information Systems* (London: Springer Verlag) p 299–310.
- DiMicco, J.M., Greenwald, A., ve Maes, P., 2002, Learning curve: A simulation-based approach to dynamic pricing, *Electronic Commerce Research* 3, 245–276, <https://doi.org/10.1023/A:1023427023289>.
- Domínguez-Menchero, J.S., Rivera, J., ve Torres-Manzanera, E., 2014, Optimal purchase timing in the airline market, *J. Air Transport Manage.*, 40, pp. 137–143, <https://doi.org/10.1016/j.jairtraman.2014.06.010>.
- Dube, P., Borkar, V.S., ve Manjunath, D., 2002, Differential join prices for parallel queues: Social optimality, dynamic pricing algorithms and application to internet pricing, *Proceedings.Twenty-First Annual Joint Conference of the IEEE Computer and Communications Societies*, pp. 276–283 vol.1, doi: 10.1109/INFCOM.2002.1019269.
- Elmaghraby, W., ve Keskinocak, P., 2003, Dynamic pricing: Research overview, current practices and future directions, *Management Science* 49 (10): 1287–1309, <https://doi.org/10.1287/mnsc.49.10.1287.17315>.
- Elmaghraby, W., 2005, Auctions and pricing in e-marketplaces, In Handbook of Quantitative Supply Chain Analysis: Modelling in the E-Business Era, *International Series in Operations Research and Management Science*, Kluwer Academic Publishers, Norwell, MA.
- Etienne, B., 2019, *Time Series in Python — Exponential Smoothing and ARIMA processes*, <https://towardsdatascience.com/time-series-in-python-exponential-smoothing-and-arima-processes-2c67f2a52788>, [Ziyaret tarihi: 23 Aralık 2020].
- Etzioni, O., Tuchinda, R., Knoblock, ve C.A., Yates, A., 2003, To buy or not to buy: mining airfare data to minimize ticket purchase price, *Proceedings of the ninth ACM*

- SIGKDD international conference on Knowledge discovery and data mining*, 119–128, <https://doi.org/10.1145/956750.956767>.
- Federgruen, A., ve Heching, A., 1999, Combined pricing and inventory control under uncertainty, *Operations Research*, 47 (3): 454–475, <https://doi.org/10.1287/opre.47.3.454>.
- Fedorco, U., Hospodka, J., 2013, Airline Pricing Strategies in European Airline Market L'.
- Friedman, J., Hastie, T., Tibshirani, R., 2000, Additive logistic regression: a statistical view of boosting (with discussion and a rejoinder by the authors). *The annals of statistics*, 28 (2), 337–407, <https://projecteuclid.org/euclid.aos/1016218223>, [Ziyaret tarihi: 8 Aralık 2020].
- Gallego, G., ve Ryzin, G., 1994, Optimal dynamic pricing of inventories with stochastic demand over finite horizons, *Management Science*, 40 (8): 999–1020, <https://doi.org/10.1287/mnsc.40.8.999>.
- Greenwald, A., Kephart, J.O., ve Tesauro, G.J., 1999, Strategic pricebot dynamics, *Proceedings of the 1st ACM Conference on Electronic Commerce (EC-99)* (New York: ACM Press), pages 58-67, <https://doi.org/10.1145/336992.337008>.
- Groves, W. ve Gini, M., 2013, An agent for optimizing airline ticket purchasing, *Proceedings of the 2013 International Conference on Autonomous agents and multi-agent systems*, Richland, SC.
- Groves, W., ve Gini, M., 2015, On optimizing airline ticket purchase timing, *ACM Transactions on Intelligent Systems and Technology (TIST)*, 7 (1): 1-28, <https://doi.org/10.1145/2733384>.
- Guo, T., Lin, T., ve Antulov-Fantulin, N., 2019, Exploring Interpretable LSTM Neural Networks over Multi-Variable Data, *International Conference on Machine Learning (ICML)*, <https://arxiv.org/abs/1905.12034>.
- Gupta, M., Ravikumar, K., ve Kumar, M., 2002, Adaptive strategies for price markdown in a multiunit descending price auction: A comparative study, *IEEE International Conference on Systems, Man and Cybernetics*, pp. 373-378, doi: 10.1109/ICSMC.2002.1168003.
- Hill, T., O'Connor, M., ve Remus, W., 1996, Neural network models for time series forecasts, *Management Science* (42), 1082-1092. <https://doi.org/10.1287/mnsc.42.7.1082>.
- Hochreiter, S., ve Schmidhuber, J., 1997, Long Short-Term Memory, *Neural Computation*, 9 (8):1735-1780, <https://doi.org/10.1162/neco.1997.9.8.1735>.

- Hu, J., ve Zhang, Y., 2002, Online reinforcement learning in multiagent systems, url:cimon.rochester.edu/public-html/papers/priceagent1.pdf
- Kalagnanam, J., ve Parkes, D., 2005, Auctions, bidding and exchange design, *In Handbook of Quantitative supply chain analysis: Modelling in the e-business era*.
- Karasu, S., Altan, A., Bekiros, S., ve Ahmad, W., 2020, A new forecasting model with wrapper-based feature selection approach using multi-objective optimization technique for chaotic crude oil time series, *Energy*, (212) 118750, <https://doi.org/10.1016/j.energy.2020.118750>.
- Kephart, J. O., ve Tesauro, G. J., 2000, Pseudo-convergent Q-learning by competitive pricebots, *Proceedings of 17th International Conference on Machine Learning* (San Francisco, CA: Morgan Kaufmann) pages 463–470.
- Lantseva, A., Mukhina, K., Nikishova, A., Ivanov, S., ve Knyazkov, K., 2015, Data-driven Modeling of Airlines Pricing, *Procedia Computer Science*, 66, pp. 267–276, <https://doi.org/10.1016/j.procs.2015.11.032>.
- Leloup, B., ve Deveau, L., 2001, Dynamic pricing on the internet: Theory and simulations, *Journal of Electronic Commerce Research*, 1 (3): 265–276, <https://doi.org/10.1023/A:1011546021787>.
- Li, L., ve Chu, K., 2017, Prediction of real estate price variation based on economic parameters, *International Conference on Applied System Innovation (ICASI)*, Sapporo, pp. 87–90, doi: 10.1109/ICASI.2017.7988353.
- Li, Y., ve Li, Z., 2018, Design and implementation of ticket price forecasting system, *AIP Conference Proceedings* 1967, 040009, <https://doi.org/10.1063/1.5039083>.
- Li, Y., Wu, H., ve Liu, H., 2018, Multi-step wind speed forecasting using EWT decomposition. LSTM principal computing. RELM subordinate computing and IEWT reconstruction, *Energy Conversion and Management*, 167:203–19, <https://doi.org/10.1016/j.enconman.2018.04.082>.
- Littlewood, K., 1972, Forecasting and control of passenger bookings, *Journal of Revenue and Pricing Management* 4 (2): 111–123, <https://doi.org/10.1057/palgrave.rpm.5170134>.
- Malighetti, P., Paleari, S., ve Redondi, R., 2009, Pricing strategies of low-cost airlines: The Ryanair case study, *Journal of Air Transport Management*, 15 (4), pp. 195–203, <https://doi.org/10.1016/j.jairtraman.2008.09.017>.

- McHugh, K., 2018, *PricingNet: modelling the global airline industry with neural networks*, <https://hackernoon.com/pricingnet-modelling-the-global-airline-industry-with-neural-networks-833844d20ea6>, [Ziyaret tarihi: 6 Aralık 2020].
- Montavon, G., Samek, W., ve Müller, K.R., 2018, Methods for interpreting and understanding deep neural networks, *Digital Signal Processing*, (73) 1-15. <https://doi.org/10.1016/j.dsp.2017.10.011>.
- Morris, J., Ree, P., ve Maes, P., 2000, Sardine: Dynamic seller strategies in an auction marketplace. *Proceedings of Second ACM Conference on Electronic Commerce (EC-00)* (New York: ACM Press) p 128–134.
- Mottini, A., ve Acuna-Agost, R., 2017, Deep Choice Model Using Pointer Networks for Airline Itinerary Prediction, *Conference: the 23rd ACM SIGKDD International Conference*, <https://doi.org/10.1145/3097983.3098005>.
- Narahari, Y., ve Dayama, P., 2005, Combinatorial auctions for electronic business, *Sadhana* 30, pp. 179-211, <https://doi.org/10.1007/BF02706244>.
- Narangajavana, Y., Garrigos-Simon, F.J., García, J.S., ve Forgas-Coll, S., 2014, Prices, prices and prices: A study in the airline sector, *Tourism Management*, 41, pp. 28-42, <https://doi.org/10.1016/j.tourman.2013.08.008>.
- Pak, K., ve Piersa, N., 2002, Airline Revenue Management: An Overview of OR Techniques 1982-2001, *Econometric Institute Report EI* 2002-03.
- Papadakis, M., 2012, *Predicting Airfare Prices*, <https://www.semanticscholar.org/paper/Predicting-Airfare-Prices-Papadakis/28b471f2ee92e6eabc1191f80f8c5117e840eadb?p2df>, [Ziyaret tarihi: 6 Kasım 2020].
- Qin, Y., Song, D., Chen, H., Cheng, W., Jiang, G., ve Cottrel, G.W., 2017, *A Dual Stage Attention-Based Recurrent Neural Network for Time Series Prediction*, <https://arxiv.org/abs/1704.02971>, [Ziyaret tarihi: 22 Ağustos 2020].
- Quantilus, 2020, *Why is Machine Learning Important and How will it Impact Business?*, <https://quantilus.com/why-is-machine-learning-important-and-how-will-it-impact-business/>, [Ziyaret tarihi: 17 Haziran 2021].
- Porter, M., 2001, Strategy and the Internet, *Harvard Business Review*.
- Raju, C.V.L., Narahari, Y., ve Ravikumar, K., 2003, Applications of reinforcement learning to dynamic pricing of retail markets, *Proceedings of IEEE Conference on Electronic Commerce, CEC-03* (Los Alanitos, CA: IEEE Comput. Soc.).

- Raju, C. V. L., 2004, Learning dynamic prices in electronic markets, *Technical report, Doctoral Dissertation, Department of Computer Science and Automation, Indian Institute of Science, Bangalore*, <http://lcm.csa.iisc.ernet.in>
- Raju, C.V.L., Narahari, Y., ve Ravikumar, K., 2004, Learning non-linear dynamic prices in electronic markets with price sensitive customers, stochastic demands, and inventory replenishments, *Technical report, Electronic Enterprises Laboratory, Department of Computer Science and Automation, Indian Institute of Science, Bangalore*, <http://lcm.csa.iisc.ernet.in>.
- Raju, C.V.L., Narahari, Y., ve Ravikumar, K., 2006a, Learning dynamic prices in electronic markets with customer segmentation, *Annals of Operations Research*, 143, pp. 59-75, <https://doi.org/10.1007/s10479-006-7372-3>.
- Raju, C.V.L., Narahari, Y., ve Ravikumar, K., 2006b, Learning dynamic prices in multi-seller electronic retail markets with price sensitive customers, stochastic demands, and inventory replenishments, *IEEE Transactions on Systems Man and Cybernetics Part C (Applications and Reviews)*, 36 (1): 92-106, doi: 10.1109/TSMCC.2005.860578.
- Raut, P.P., ve Borkar, N.R., 2017, Machine Learning Algorithms: Trends, Perspectives and Prospects, *International Journal of Engineering Science and Computing*, 7 (3), pp. 4884-4891.
- Ravikumar, K., Batra, G., Saluja, R., 2002, Multi-agent learning for dynamic pricing games of service markets, *Communicated*.
- Reinartz, W., 2002, Customizing Prices in Online Markets, *SYMPHONYA Emerging Issues in Management*, n. 1.
- Richert, W., ve Coelho, L.P., 2015, *Building Machine Learning Systems with Python*, Packt Publishing, ISBN 978-1-78439-277-2.
- Rothschild, M., 1974, A two-armed bandit theory of market pricing, *Journal of Economic Theory* 9: 185–202, [https://doi.org/10.1016/0022-0531\(74\)90066-0](https://doi.org/10.1016/0022-0531(74)90066-0).
- Rusmevichientong, P., Salisbury, J.A., Truss, L.T., Van Roy, B., ve Glynn, P.W., 2005, Opportunities and Challenges in Using Online Preference Data for Vehicle Pricing: A Case Study at General Motors, *Journal of Revenue and Pricing Management* 5(1), DOI:10.1057/palgrave.rpm.5160011.
- Santana, E.J., Mastelini, S.M., ve Barbon, S., 2017, Deep Regressor Stacking for Air Ticket Prices Prediction, *XIII Brazilian Symposium on Information Systems: Information*

- Systems for Participatory Digital Governance*, pp. 25-31, <https://doi.org/10.5753/sbsi.2017.6022>.
- Saxon, S., ve Weber, M., 2017, *A Better Approach to Airline Costs*, <https://www.mckinsey.com/industries/travel-transport-and-logistics/our-insights/a-better-approach-to-airline-costs>, [Ziyaret tarihi: 22 Eylül 2020].
- Scientistcafe, 2017, *Types of Machine Learning Algorithm*, <https://scientistcafe.com/2017/07/08/machinelearningal>, [Ziyaret tarihi: 17 Haziran 2021].
- Shankar, V., Rangaswamy, A., Pusateri, M., 1999, *The Online Medium and Customer Price Sensitivity*, *Working Paper*.
- Shapiro, C., ve Varian, H. R., 1998, *Information Rules: A Strategic Guide to the Network Economy*, Harvard Business School Press, ISBN-13: 978-0875848631.
- Smith, M., Bailey, J., Brynjolfsson, E., 2001, *Understanding Digital Markets: Review and Assessment*, in *Understanding the Digital Economy*, *SSRN Electronic Journal*, <http://dx.doi.org/10.2139/ssrn.290326>.
- Tziridis, K., Kalampokas, T., Papakostas, G.A., ve Diamantaras, K.I., 2017, *Airfare prices prediction using machine learning techniques*, *25th European Signal Processing Conference (EUSIPCO)*, pp. 1036-1039.
- Varedi, M., 2010, *Forecasting seat sales in passenger airlines: introducing the round-trip mode*, Thesis (MSc), University of Waterloo, Ontario, Canada. <http://hdl.handle.net/10012/5715>, [Ziyaret tarihi: 5 Aralık 2020].
- Varian, H.R., 1996, *Differential pricing and efficiency*, *First Monday*, 1.
- Vu, V.H., Minh, Q.T., ve Phung, P.H., 2018, *An airfare prediction model for developing markets*, *2018 International Conference on Information Networking (ICOIN)*, Chiang Mai, pp. 765–770.
- Wang, Y., 2016, *Dynamic pricing considering strategic customers*, *International Conference on Logistics, Informatics and Service Sciences (LISS)*, Sydney, NSW, pp. 1–5, doi: 10.1109/LISS.2016.7854471.
- Welling, M., 2011, *A First Encounter with Machine Learning*, *Donald Bren School of Information and Computer Science University of California Irvine*.
- Wen, C.H., ve Chen P.H., 2017, *Passenger booking timing for low-cost airlines: A continuous logit approach*. *Journal of Air Transport Management*, xxx, 1–9. <https://doi.org/10.1016/j.jairtraman.2017.06.030>.

Wikipedia, 2020, *Autoregressive integrated moving average*, https://en.wikipedia.org/wiki/Autoregressive_integrated_moving_average, [Ziyaret tarihi: 9 Aralık 2020].

Wohlfarth, T., Clemencon, S., Roueff, F., ve Casellato, X., 2011, A Data-Mining Approach to Travel Price Forecasting, *2011 10th International Conference on Machine Learning and Applications and Workshops*, Honolulu, HI, pp. 84–89, doi: 10.1109/ICMLA.2011.11.

Xu, Y., ve Cao, J., 2017, OTPS: A decision support service for optimal airfare Ticket Purchase, *IEEE International Conference on Big Data*, Boston, MA, pp. 1363-1368, doi: 10.1109/BigData.2017.8258068.



EKLER

Ek1. IMV-LSTM Kaynak Kodu

```

import torch
from torch import nn
from torch.utils.data import TensorDataset, DataLoader

import pandas as pd

import numpy as np
import matplotlib.pyplot as plt
from sklearn.metrics import r2_score

class IMVTensorLSTM(torch.jit.ScriptModule):

    __constants__ = ["n_units", "input_dim"]
    def __init__(self, input_dim, output_dim, n_units, init_std=0.02):
        super().__init__()
        torch.manual_seed(0)
        self.U_j = nn.Parameter(torch.randn(input_dim, 1, n_units)*init_std)
        self.U_i = nn.Parameter(torch.randn(input_dim, 1, n_units)*init_std)
        self.U_f = nn.Parameter(torch.randn(input_dim, 1, n_units)*init_std)
        self.U_o = nn.Parameter(torch.randn(input_dim, 1, n_units)*init_std)
        self.W_j = nn.Parameter(torch.randn(input_dim, n_units, n_units)*init_std)
        self.W_i = nn.Parameter(torch.randn(input_dim, n_units, n_units)*init_std)
        self.W_f = nn.Parameter(torch.randn(input_dim, n_units, n_units)*init_std)
        self.W_o = nn.Parameter(torch.randn(input_dim, n_units, n_units)*init_std)
        self.b_j = nn.Parameter(torch.randn(input_dim, n_units)*init_std)
        self.b_i = nn.Parameter(torch.randn(input_dim, n_units)*init_std)
        self.b_f = nn.Parameter(torch.randn(input_dim, n_units)*init_std)
        self.b_o = nn.Parameter(torch.randn(input_dim, n_units)*init_std)
        self.F_alpha_n = nn.Parameter(torch.randn(input_dim, n_units, 1)*init_std)
        self.F_alpha_n_b = nn.Parameter(torch.randn(input_dim, 1)*init_std)
        self.F_beta = nn.Linear(2*n_units, 1)
        self.Phi = nn.Linear(2*n_units, output_dim)
        self.n_units = n_units
        self.input_dim = input_dim

    @torch.jit.script_method
    def forward(self, x):
        h_tilda_t = torch.zeros(x.shape[0], self.input_dim, self.n_units).cuda()
        c_tilda_t = torch.zeros(x.shape[0], self.input_dim, self.n_units).cuda()
        outputs = torch.jit.annotate(List[Tensor], [])
        for t in range(x.shape[1]):
            # eq 1

```

```

j_tilda_t = torch.tanh(torch.einsum("bij,ijk->bik", h_tilda_t, self.W_j) + \
    torch.einsum("bij,jik->bjk", x[:,t,:].unsqueeze(1), self.U_j) + self.b_j)
# eq 5
i_tilda_t = torch.sigmoid(torch.einsum("bij,ijk->bik", h_tilda_t, self.W_i) + \
    torch.einsum("bij,jik->bjk", x[:,t,:].unsqueeze(1), self.U_i) + self.b_i)
f_tilda_t = torch.sigmoid(torch.einsum("bij,ijk->bik", h_tilda_t, self.W_f) + \
    torch.einsum("bij,jik->bjk", x[:,t,:].unsqueeze(1), self.U_f) + self.b_f)
o_tilda_t = torch.sigmoid(torch.einsum("bij,ijk->bik", h_tilda_t, self.W_o) + \
    torch.einsum("bij,jik->bjk", x[:,t,:].unsqueeze(1), self.U_o) + self.b_o)
# eq 6
c_tilda_t = c_tilda_t*f_tilda_t + i_tilda_t*j_tilda_t
# eq 7
h_tilda_t = (o_tilda_t*torch.tanh(c_tilda_t))
outputs += [h_tilda_t]
outputs = torch.stack(outputs)
# eq 8
alphas = torch.tanh(torch.einsum("btij,ijk->btik", outputs, self.F_alpha_n) + self.F_alpha_n_b)
alphas = torch.exp(alphas)
alphas = alphas/torch.sum(alphas, dim=1, keepdim=True)
g_n = torch.sum(alphas*outputs, dim=1)
hg = torch.cat([g_n, h_tilda_t], dim=2)
mu = self.Phi(hg)
betas = torch.tanh(self.F_beta(hg))
betas = torch.exp(betas)
betas = betas/torch.sum(betas, dim=1, keepdim=True)
mean = torch.sum(betas*mu, dim=1)

return mean, alphas, betas

def finda10(a,b,idx):
    cnt = 0
    for i in range(len(a)):
        if abs(a[i]/b[i]-1) < idx/100:
            cnt +=1
    return cnt / len(a)

def rmspe(y_true, y_pred):
    return np.sqrt(np.nanmean(np.square(((y_true - y_pred) / y_true))))*100

from pandas import read_csv
data = pd.read_csv('/content/gdrive/My Drive/07FLIGHTBASEFILTERING/DATA/Smoothed10.csv', header=0, parse_dates=['FlightDate'])

target = 'Price'
cols = ['FlightDate','DayOfWeek','WeekOfYear','DaysToFlight','Class','AvailableCapacity','CASKValue',

```

```

    'TargetRevenue', 'IsHoliday', 'priceTHY', 'priceAtlas', 'pricePegasus', 'Price']
train_size_end = 5829
val_size_end = 6565
depth = 1
batch_size = 40
prediction_horizon = 1

datatest = data.iloc[val_size_end:,]

X = np.zeros((len(data), depth, len(cols)))
Y = np.zeros((len(data), 1))

for i, name in enumerate(cols):
    for j in range(depth):
        X[:, j, i] = data[name].shift(depth - j - 1).fillna(method="bfill")
Y = data[target].shift(-prediction_horizon).fillna(method='ffill')

Xtest = np.zeros((len(datatest), depth, len(cols)))
Ytest = np.zeros((len(datatest), 1))

for i, name in enumerate(cols):
    for j in range(depth):
        Xtest[:, j, i] = datatest[name].shift(depth - j - 1).fillna(method="bfill")
Ytest = datatest[target].shift(-prediction_horizon).fillna(method='ffill')

X_train = X[depth:train_size_end]
y_train = Y[depth:train_size_end]

X_val = X[depth+train_size_end+1:depth+val_size_end]
y_val = Y[depth+train_size_end+1:depth+val_size_end]

X_test = Xtest[depth:]
y_test = Ytest[depth:]

X_train_min, y_train_min = X_train.min(axis=0), y_train.min(axis=0)
X_train_max, y_train_max = X_train.max(axis=0), y_train.max(axis=0)

X_train = (X_train - X_train_min)/(X_train_max - X_train_min + 1e-9)
X_val = (X_val - X_train_min)/(X_train_max - X_train_min + 1e-9)
X_test = (X_test - X_train_min)/(X_train_max - X_train_min + 1e-9)

y_train = (y_train - y_train_min)/(y_train_max - y_train_min + 1e-9)
y_val = (y_val - y_train_min)/(y_train_max - y_train_min + 1e-9)
y_test = (y_test - y_train_min)/(y_train_max - y_train_min + 1e-9)

X_train_t = torch.Tensor(X_train)
X_val_t = torch.Tensor(X_val)

```

```

X_test_t = torch.Tensor(X_test)
y_train_t = torch.Tensor(y_train.values)
y_val_t = torch.Tensor(y_val.values)
y_test_t = torch.Tensor(y_test.values)

train_loader = DataLoader(TensorDataset(X_train_t, y_train_t), shuffle=True, batch_size=batch_size)
val_loader = DataLoader(TensorDataset(X_val_t, y_val_t), shuffle=False, batch_size=batch_size)
test_loader = DataLoader(TensorDataset(X_test_t, y_test_t), shuffle=False, batch_size=batch_size)

model = IMVTensorLSTM(X_train.shape[2], 1, 512).cuda()
opt = torch.optim.Adam(model.parameters(), lr=0.001)

epoch_scheduler = torch.optim.lr_scheduler.StepLR(opt, 20, gamma=0.9)

from sklearn.metrics import mean_squared_error
epochs = 1000
loss = nn.MSELoss()
patience = 35
min_val_loss = 9999
counter = 0
for i in range(epochs):
    mse_train = 0

    for batch_x, batch_y in train_loader :
        batch_x = batch_x.cuda()
        batch_y = batch_y.cuda()
        opt.zero_grad()
        y_pred, alphas, betas = model(batch_x)
        y_pred = y_pred.squeeze(1)
        l = loss(y_pred, batch_y)
        l.backward()
        mse_train += l.item()*batch_x.shape[0]
    opt.step()
    epoch_scheduler.step()
    with torch.no_grad():
        mse_val = 0
        preds = []
        true = []
        for batch_x, batch_y in val_loader:
            batch_x = batch_x.cuda()
            batch_y = batch_y.cuda()
            output, alphas, betas = model(batch_x)
            output = output.squeeze(1)
            preds.append(output.detach().cpu().numpy())

```

```

        true.append(batch_y.detach().cpu().numpy())
        mse_val += loss(output, batch_y).item()*batch_x.shape[0]
    preds = np.concatenate(preds)
    true = np.concatenate(true)

    if min_val_loss > mse_val**0.5:
        min_val_loss = mse_val**0.5
        print("Saving...")
        torch.save(model.state_dict(), "/content/gdrive/My Drive/Colab Notebooks/Checkpoints/SS_1.pt")
        counter = 0
    else:
        counter += 1

    if counter == patience:
        break
    print("Iter: ", i, "train: ", (mse_train/len(X_train_t))**0.5, "val: ", (mse_val/len(X_val_t))**0.5)
    if(i % 10 == 0):
        preds = preds*(y_train_max - y_train_min) + y_train_min
        true = true*(y_train_max - y_train_min) + y_train_min
        mse = mean_squared_error(true, preds)
        print("mse: ", mse)

model.load_state_dict(torch.load("/content/gdrive/My Drive/Colab Notebooks/Checkpoints/SS_1.pt"))

with torch.no_grad():

    mse_val = 0
    preds = []
    true = []
    alphas = []
    betas = []
    for batch_x, batch_y in test_loader:

        batch_x = batch_x.cuda()
        batch_y = batch_y.cuda()
        output, a, b = model(batch_x)
        output = output.squeeze(1)
        preds.append(output.detach().cpu().numpy())
        true.append(batch_y.detach().cpu().numpy())
        alphas.append(a.detach().cpu().numpy())
        betas.append(b.detach().cpu().numpy())
        mse_val += loss(output, batch_y).item()*batch_x.shape[0]
    preds = np.concatenate(preds)
    true = np.concatenate(true)

```

```

alphas = np.concatenate(alphas)
betas = np.concatenate(betas)

preds = preds*(y_train_max - y_train_min) + y_train_min
true = true*(y_train_max - y_train_min) + y_train_min

print(" mse :", mean_squared_error(true, preds))
print("a10 : ", finda10(preds,true,10))
print("a20 : ", finda10(preds,true,20))
print("r2 :", r2_score(preds,true))
print("rmspe : ", rmspe(true, preds))

# Calculate mean absolute percentage error (MAPE)
errors = abs(preds - true)
mape = 100 * (errors / true)

# Calculate and display accuracy
accuracy = 100 - np.mean(mape)
print('Accuracy:', round(accuracy, 2), '%.')

```

Ek2. VBS IMV-LSTM Kaynak Kodu

```

import torch
from torch import nn
from torch.utils.data import TensorDataset, DataLoader

import pandas as pd

import numpy as np
import matplotlib.pyplot as plt
from sklearn.metrics import r2_score

class IMVTensorLSTM(torch.jit.ScriptModule):
    __constants__ = ["n_units", "input_dim"]
    def __init__(self, input_dim, output_dim, n_units, init_std=0.02):
        super().__init__()
        torch.manual_seed(0)
        self.U_j = nn.Parameter(torch.randn(input_dim, 1, n_units)*init_std)
        self.U_i = nn.Parameter(torch.randn(input_dim, 1, n_units)*init_std)
        self.U_f = nn.Parameter(torch.randn(input_dim, 1, n_units)*init_std)
        self.U_o = nn.Parameter(torch.randn(input_dim, 1, n_units)*init_std)
        self.W_j = nn.Parameter(torch.randn(input_dim, n_units, n_units)*init_std)
        self.W_i = nn.Parameter(torch.randn(input_dim, n_units, n_units)*init_std)
        self.W_f = nn.Parameter(torch.randn(input_dim, n_units, n_units)*init_std)
        self.W_o = nn.Parameter(torch.randn(input_dim, n_units, n_units)*init_std)

```

```

self.b_j = nn.Parameter(torch.randn(input_dim, n_units)*init_std)
self.b_i = nn.Parameter(torch.randn(input_dim, n_units)*init_std)
self.b_f = nn.Parameter(torch.randn(input_dim, n_units)*init_std)
self.b_o = nn.Parameter(torch.randn(input_dim, n_units)*init_std)
self.F_alpha_n = nn.Parameter(torch.randn(input_dim, n_units, 1)*init_std)
self.F_alpha_n_b = nn.Parameter(torch.randn(input_dim, 1)*init_std)
self.F_beta = nn.Linear(2*n_units, 1)
self.Phi = nn.Linear(2*n_units, output_dim)
self.n_units = n_units
self.input_dim = input_dim

```

@torch.jit.script_method

def forward(self, x):

```

    h_tilda_t = torch.zeros(x.shape[0], self.input_dim, self.n_units).cuda()
    c_tilda_t = torch.zeros(x.shape[0], self.input_dim, self.n_units).cuda()
    outputs = torch.jit.annotate(List[Tensor], [])

```

for t in range(x.shape[1]):

eq 1

```

    j_tilda_t = torch.tanh(torch.einsum("bij,ijk->bik", h_tilda_t, self.W_j) + \
                             torch.einsum("bij,jik->bjk", x[:,t,:].unsqueeze(1), self.U_j) + self.b_j)

```

eq 5

```

    i_tilda_t = torch.sigmoid(torch.einsum("bij,ijk->bik", h_tilda_t, self.W_i) + \
                               torch.einsum("bij,jik->bjk", x[:,t,:].unsqueeze(1), self.U_i) + self.b_i)
    f_tilda_t = torch.sigmoid(torch.einsum("bij,ijk->bik", h_tilda_t, self.W_f) + \
                               torch.einsum("bij,jik->bjk", x[:,t,:].unsqueeze(1), self.U_f) + self.b_f)
    o_tilda_t = torch.sigmoid(torch.einsum("bij,ijk->bik", h_tilda_t, self.W_o) + \
                               torch.einsum("bij,jik->bjk", x[:,t,:].unsqueeze(1), self.U_o) + self.b_o)

```

eq 6

```

    c_tilda_t = c_tilda_t*f_tilda_t + i_tilda_t*j_tilda_t

```

eq 7

```

    h_tilda_t = (o_tilda_t*torch.tanh(c_tilda_t))
    outputs += [h_tilda_t]
    outputs = torch.stack(outputs)

```

eq 8

```

    alphas = torch.tanh(torch.einsum("btij,ijk->btik", outputs, self.F_alpha_n) + self.F_alpha_n_b)
    alphas = torch.exp(alphas)
    alphas = alphas/torch.sum(alphas, dim=1, keepdim=True)
    g_n = torch.sum(alphas*outputs, dim=1)
    hg = torch.cat([g_n, h_tilda_t], dim=2)
    mu = self.Phi(hg)

```

```

betas = torch.tanh(self.F_beta(hg))
betas = torch.exp(betas)
betas = betas/torch.sum(betas, dim=1, keepdim=True)
mean = torch.sum(betas*mu, dim=1)

return mean, alphas, betas

def finda10(a,b,idx):
    cnt = 0
    for i in range(len(a)):
        if abs(a[i]/b[i]-1) < idx/100:
            cnt +=1
    return cnt / len(a)

def rmspe(y_true, y_pred):
    return np.sqrt(np.nanmean(np.square(((y_true - y_pred) / y_true))))*100

from pandas import read_csv
data = pd.read_csv('/content/gdrive/My Drive/07FLIGHTBASEFILTERING/DATA/Smoothe
d10.csv', header=0, parse_dates=['FlightDate'])

target = 'Price'
cols = ['FlightDate', 'DayOfWeek', 'WeekOfYear', 'DaysToFlight', 'Class', 'AvailableCapacity', 'C
ASKValue',
        'TargetRevenue', 'IsHoliday', 'priceTHY', 'priceAtlas', 'pricePegasus', 'Price']
train_size_end = 5829
val_size_end = 6565
depth = 1
prediction_horizon = 1

datatest = data.iloc[val_size_end:,]

flightDatesTrain = np.unique(data.values[:train_size_end,0])
flightDatesVal = np.unique(data.values[train_size_end+1:val_size_end,0])
flightDatesTest = np.unique(datatest.values[:,0])

X = np.zeros((len(data), depth, len(cols)))
Y = np.zeros((len(data), 1))

for i, name in enumerate(cols):

    for j in range(depth):

        X[:, j, i] = data[name].shift(depth - j - 1).fillna(method="bfill")

Y = data[target].shift(-prediction_horizon).fillna(method='ffill')

```

```

xmin, ymin = X.min(axis=0), Y.min(axis=0)
xmax, ymax = X.max(axis=0), Y.max(axis=0)

def adjustdata(subdata):
    X = np.zeros((len(subdata), depth, len(cols)))
    Y = np.zeros((len(subdata), 1))

    for i, name in enumerate(cols):

        for j in range(depth):

            X[:, j, i] = subdata[name].shift(depth - j - 1).fillna(method="bfill")
            Y = subdata[target].shift(-prediction_horizon).fillna(method='ffill')

    retx = X[depth:len(X)]
    rety = Y[depth:len(X)]

    retx = (retx - xmin)/(xmax - xmin + 1e-9)
    rety = (rety - ymin)/(ymax - ymin + 1e-9)

    return retx, rety

print("=====", data.shape, data.shape[1] )
model = IMVTensorLSTM(data.shape[1], 1, 256).cuda()
opt = torch.optim.Adam(model.parameters(), lr=0.001)

epoch_scheduler = torch.optim.lr_scheduler.StepLR(opt, 20, gamma=0.9)

from sklearn.metrics import mean_squared_error, mean_absolute_error

epochs = 500
loss = nn.MSELoss()
patience = 35
min_val_loss = 9999
loopcnt = 0

from torch import autograd

for ii in range(5):

    counter = 0
    rowcnt = 0
    res = np.zeros((epochs, len(flightDatesTrain)))
    for i in range(epochs):

        mse_train = 0
        for t_i in range(0, len(flightDatesTrain)):

```

```
mask=(flightDatesTrain[t_i] == data.values[:,0])
subdata = pd.DataFrame(data.values[mask,:], columns=cols)
batch_x, batch_y = adjustdata(subdata)
```

```
batch_x = torch.Tensor(batch_x).cuda()
batch_y = torch.Tensor(batch_y.values).cuda()
opt.zero_grad()
y_pred, alphas, betas = model(batch_x)
y_pred = y_pred.squeeze(1)
l = loss(y_pred, batch_y)
l.backward()
mse_train += l.item()*batch_x.shape[0]
opt.step()
```

```
res[i][t_i] = mse_train
```

```
with torch.no_grad():
```

```
mse_val = 0
preds = []
true = []
for t_i2 in range(0, len(flightDatesVal)):
```

```
    mask=(flightDatesVal[t_i2] == data.values[:,0])
    subdata = pd.DataFrame(data.values[mask,:], columns=cols)
    batch_x, batch_y = adjustdata(subdata)
```

```
    batch_x = torch.Tensor(batch_x).cuda()
    batch_y = torch.Tensor(batch_y.values).cuda()
    output, alphas, betas = model(batch_x)
    output = output.squeeze(1)
    preds.append(output.detach().cpu().numpy())
    true.append(batch_y.detach().cpu().numpy())
    mse_val += loss(output, batch_y).item()*batch_x.shape[0]
```

```
preds = np.concatenate(preds)
true = np.concatenate(true)
```

```
if min_val_loss > mse_val**0.5:
```

```
    min_val_loss = mse_val**0.5
```

```
    print("Saving...")
```

```
    torch.save(model.state_dict(), "/content/gdrive/My Drive/07FLIGHTBASEFILTERIN
G/CHECKPOINTS/SD_"+str(depth)+".pt")
```

```
    counter = 0
```

```
else:
```

```
    counter += 1
```

```

if counter == patience:
    rowcnt = i
    break

if(i % 10 == 0 and t_i % flightDatesTrain.shape[0] == 0 ):

    preds = preds*(ymax - ymin) + ymin
    true = true*(ymax - ymin) + ymin
    mse = mean_squared_error(true, preds)
    mae = mean_absolute_error(true, preds)
    print("mse: ", mse, "mae: ", mae)
    plt.figure(figsize=(12, 6))
    plt.plot(preds)
    plt.plot(true)
    plt.show()
    epoch_scheduler.step()
    #mx = max(BB)
    print("=== INDICES ===",ind)
    #maxpos = BB.tolist().index(mx)
    #print("=====",rowcnt, maxpos, mx, ">>>>>>>>> DROPPED")
    flightDatesTrain = np.delete(flightDatesTrain,ind,None)
    #np.savetxt('/content/gdrive/My Drive/MYTEST/SD14_'+ str(loopcnt)+'.csv', res, delimiter=
    ', ', fmt='%f')
    loopcnt +=1

    model.load_state_dict(torch.load("/content/gdrive/My Drive/07FLIGHTBASEFILTERING/
CHECKPOINTS/SD_"+str(depth)+".pt"))

with torch.no_grad():

    mse_val = 0
    preds = []
    true = []
    alphas = []
    betas = []

    for t_i2 in range(0, len(flightDatesTest)):

        if len(subdata) > 1 :

            batch_x = torch.Tensor(batch_x).cuda()
            batch_y = torch.Tensor(batch_y.values).cuda()
            output, a, b = model(batch_x)
            output = output.squeeze(1)
            preds.append(output.detach().cpu().numpy())
            true.append(batch_y.detach().cpu().numpy())

```

```

    alphas.append(a.detach().cpu().numpy())
    betas.append(b.detach().cpu().numpy())
    mse_val += loss(output, batch_y).item()*batch_x.shape[0]

preds = np.concatenate(preds)
true = np.concatenate(true)
alphas = np.concatenate(alphas)
betas = np.concatenate(betas)

preds = preds*(ymax - ymin) + ymin
true = true*(ymax - ymin) + ymin

mse = mean_squared_error(true, preds)
print(ii, "===== mse :", mse)

plt.figure(figsize=(20, 10))
plt.plot(preds[-400:])
plt.plot(true[-400:])
plt.show()

alphas = alphas.mean(axis=0)
betas = betas.mean(axis=0)

alphas = alphas[..., 0]
betas = betas[..., 0]

alphas = alphas.transpose(1, 0)

fig, ax = plt.subplots(figsize=(10, 10))
im = ax.imshow(alphas)
ax.set_xticks(np.arange(depth))
ax.set_yticks(np.arange(len(cols)))
ax.set_xticklabels(["t-"+str(i) for i in np.arange(depth)])
ax.set_yticklabels(cols)
for i in range(len(cols)):
    for j in range(depth):
        text = ax.text(j, i, round(alphas[i, j], 3),
                        ha="center", va="center", color="w")
ax.set_title("Importance of features and timesteps")
#fig.tight_layout()
plt.show()

print(" mse :", mean_squared_error(true, preds))
print("a10 : ", finda10(preds,true,10))
print("a20 : ", finda10(preds,true,20))
print("r2 :", r2_score(preds,true))
print("rmspe : ", rmspe(true, preds))

```

```
# Calculate mean absolute percentage error (MAPE)
errors = abs(preds - true)
mape = 100 * (errors / true)
```

```
# Calculate and display accuracy
accuracy = 100 - np.mean(mape)
print('Accuracy:', round(accuracy, 2), '%.')
```

|



