

**TALEP TAHMİNİNDE MAKİNE ÖĞRENMESİ VE ZAMAN SERİLERİ
TEMELLİ BİR KARAR DESTEK SİSTEMİ**

SETAR RİZVANCHE

Yüksek Lisans Tezi

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Bilim Dalı

Danışman: Doç. Dr. Gürkan ÖZTÜRK

Eskişehir

Eskişehir Teknik Üniversitesi

Lisansüstü Eğitim Enstitüsü

Temmuz 2020

ÖZET

TALEP TAHMİNİNDE MAKİNE ÖĞRENMESİ VE ZAMAN SERİLERİ TEMELLİ BİR KARAR DESTEK SİSTEMİ

SETAR RİZVANCHE

Endüstri Mühendisliği Anabilim Dalı

Endüstri Mühendisliği Bilim Dalı

Eskişehir Teknik Üniversitesi, Lisansüstü Eğitim Enstitüsü, Temmuz 2020

Danışman: Doç. Dr. Gürkan ÖZTÜRK

Gerçek hayatı modelleyen bir tahmin uygulaması geliştirmek oldukça zor olabilir. Zaman serilerini modellemek ve onlar üzerinde tahmin yapmak, içlerinde barındırdıkları doğrusal ve doğrusal olmayan örüntüler nedeniyle karmaşık bir hal alabilir. Bu gibi durumlarda, farklı tekniklerin sahip oldukları mekanizmaları bir yerde birleştirdiği için, tekil modellere göre doğruluk açısından daha iyi sonuçlar elde etmek üzere hibrit modellerin kullanımı öne çıkmaktadır. Bu çalışmada, bir gerçek hayat tahmin problemi için doğrusal ve doğrusal olmayan yaklaşımların yanı sıra hibrit modelleri de model tabanında barındıran, model yönelimli bir web tabanlı karar destek sistemi geliştirilmiştir. Model tabanında yer alan ARIMA (Bütünleşik Otoregresif Hareketli Ortalama), LSTM (Uzun Kısa Vadeli Bellek Ağları) ve hibrit modelin performansları bitcoin değer tahmin örneği üzerinden gösterilmiştir. Ayrıca gerçek hayat uygulama problemi üzerinden oluşturulmuş örnek veri kümeleri için yöntemlerin performansları karşılaştırmalı olarak sunulmuş ve geliştirilen karar destek sisteminin bileşenleri detaylı olarak açıklanmıştır.

Anahtar Sözcükler: Karar destek sistemi, Yapay zeka, ARIMA, LSTM, Hibrit model.

ABSTRACT

A DECISION SUPPORT SYSTEM BASED ON MACHINE LEARNING AND TIME SERIES FOR DEMAND FORECASTING

SETAR RİZVANCHE

Department of Industrial Engineering

Programme in Industrial Engineering

Eskişehir Technical University, Institute of Graduate Programs, July 2020

Supervisor: Assoc. Prof. Dr. Gürkan ÖZTÜRK

Developing a real life modeling application can be quite difficult. Modeling and predicting time series can be complicated by the linear and nonlinear patterns they contain. In such cases, the use of hybrid models is prominent in order to obtain better results in terms of accuracy compared to individual models, as it combines the mechanisms that different techniques have in one place. In this study, a model-oriented web-based decision support system was developed for a real-life prediction problem that includes hybrid models as well as linear and nonlinear approaches. The performances of ARIMA (Integrated Autoregressive Moving Average), LSTM (Long Short Term Memory Networks) and hybrid model in the model base are shown on the example of bitcoin value estimation. In addition, the performances of the methods are presented comparatively for the sample datasets created based on real life application problem and the components of the developed decision support system are explained in detail.

Keywords: Decision support systems, Artificial intelligence, ARIMA, LSTM, Hybrid Model.

TEŞEKKÜR

Bu tezin yazılması aşamasında, kıymetli bilgi birikimi ve tecrübeleriyle bana yol göstererek çalışmamı sahiplenip titizlikle takip eden değerli danışman hocam Doç. Dr. Gürkan ÖZTÜRK'e teşekkürlerimi sunarım.

Beni bu yaşa getiren ve çalışmalarım boyunca her türlü destekleriyle beni hiçbir zaman yalnız bırakmayan canım aileme şükranlarımı sunarım.

Tez sürecinde desteklerini esirgemeyen Hakan Liman, Şeref Yaşar ve Gülçin Bostanoğlu'na teşekkür ederim.

SETAR RİZVANCHE

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Eskişehir Teknik Üniversitesi tarafından kullanılan “bilimsel intihal tespit programı”yla tarandığını ve hiçbir şekilde “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçları kabul ettiğimi bildiririm.

SETAR RİZVANCHE

İÇİNDEKİLER

Sayfa

BAŞLIK SAYFASI	i
JÜRİ VE ENSTİTÜ ONAYI.....	ii
ÖZET	iii
ABSTRACT.....	iv
TEŞEKKÜR	v
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ.....	vi
İÇİNDEKİLER.....	vii
TABLolar DİZİNİ	x
ŞEKİLLER DİZİNİ	xi
GÖRSELLER DİZİNİ	xii
SİMGELER VE KISALTMALAR DİZİNİ.....	xiii
1. GİRİŞ.....	1
2. TALEP TAHMİNİ.....	7
2.1. Talep Tahmini Kavramı	7
2.2. Talep Tahmini Aşamaları.....	8
2.3. Talep Tahmininde Kullanılan Yöntemler.....	9
2.3.1. Yargıya dayalı yöntemler	10
2.3.2. Sayısal yöntemler.....	12
3. MAKİNE ÖĞRENMESİ.....	16
3.1. Yapay Zekâ	16
3.2. Makine Öğrenmesi Kavramsal	16
3.2.1. Derin öğrenme	16
3.3. Yapay Sinir Ağları Tanımı.....	17
3.4. Yapay Sinir Ağlarının Yapısı.....	18
3.4.1. Yapay sinir ağlarının temel bileşenleri.....	19
3.5. Yapay Sinir Ağlarının Mimarilerine Göre Sınıflandırması.....	25

3.5.1. İleri beslemeli ağlar	26
3.5.2. Geri beslemeli ağlar.....	26
3.6. Tekrarlayan Sinir Ağları.....	27
3.7. Uzun- Kısa Süreli Bellek Ağları.....	27
4. ZAMAN SERİLERİ	29
4.1. Zaman Serileri Yapısı.....	29
4.2. Doğrusal Zaman Serisi Modelleri.....	30
4.2.1. ARIMA model belirleme süreci	31
4.2.2. Durağan olmayan ARIMA modelleri	33
4.2.3. Mevsimsel modeller	34
5. HİBRİT	36
5.1. Hibrit Kavramı.....	36
5.2. Hibrit Modeller.....	37
5.3. Çalışmada Kullanılan Hibrit Model Yaklaşımı	39
6. KARAR DESTEK SİSTEMLERİ.....	42
6.1. Karar Destek Sistemini Oluşturan Bileşenler	42
6.2. Karar Destek Sisteminin Türleri	43
6.3. Karar Destek Sistemini Geliştirme Süreci.....	43
6.4. Uygulamada Kullanılan Karar Destek Sisteminin Model Tabanındaki Diğer Yöntemleri.....	45
7. TALEP TAHMİNİ ÜZERİNE UYGULAMA	48
7.1. İşletme Hakkında	48
7.2. Veri Hazırlık Süreci	49
7.3. Tahmin Üretim Süreci ve Kullanılan Modeller	52
7.3.1. ARIMA uygulaması	52
7.3.2. LSTM uygulaması	54
7.3.3. Hibrit model.....	56
7.3.4. Blok zincir verileri üzerine modelin denenmesi	58
7.4. Karar Destek Sisteminin Arayüzleri	59
8. SONUÇ VE ÖNERİLER.....	65

8.1. Sonuç	65
8.2. Öneriler	66
KAYNAKÇA.....	67
EK-1. UYGULAMADA KULLANILAN KÜTÜPHANELER.....	74
ÖZGEÇMİŞ	



TABLÖLAR DİZİNİ

Sayfa

Tablo 2.1. Korelasyon katsayısı değerleri ve yorumlamaları	13
Tablo 4.1. Durağan zaman verilerinde ACF ve PACF'nin teorik davranışları.....	32
Tablo 7.1. ABC analizinin özet tablosu	50
Tablo 7.2. Uygulama sürecinde seçilen ürünlerin başarı kriterleri tablosu.....	57
Tablo 7.3. Bitcoin tahmin sonuçları	59



ŞEKİLLER DİZİNİ

Sayfa

Şekil 3.1. Biyolojik sinir sistemi blok diyagramı	19
Şekil 3.2. İnsan sinir hücresi yapısı	19
Şekil 3.3. Yapay sinir hücresinin basit yapısı.....	20
Şekil 3.4. Yapay sinir hücresinin yapısı	21
Şekil 3.5. Simetrik eşik aktivasyon fonksiyonları	23
Şekil 3.6. Lineer aktivasyon fonksiyonu	23
Şekil 3.7. Sigmoid aktivasyon fonksiyonu	24
Şekil 3.8. Hiperbolik tanjant aktivasyon fonksiyonu	24
Şekil 3.9. İleri beslemeli ağ (Yavuz & Deveci, 2012).....	26
Şekil 3.10. Geri beslemeli ağ (Yavuz & Deveci, 2012)	26
Şekil 3.11. Tekrarlayan sinir ağları	27
Şekil 3.12. Uzun kısa süreli bellek ağları	28
Şekil 5.1. Hibrit model diyagramı	41

GÖRSELLER DİZİNİ

Sayfa

Görsel 6.1. Karar destek sisteminin yapısı.....	44
Görsel 7.1. ABC analiz kodları I.....	49
Görsel 7.2. ABC analiz kodları II	49
Görsel 7.3. ABC analizinin sonucu	50
Görsel 7.4. Temsil edilen verilere ait zaman veri grafiği.....	51
Görsel 7.5. Auto ARIMA ile ilgili kodlar	53
Görsel 7.6. Auto ARIMA sonucu	53
Görsel 7.7. ARIMA sonuç grafiği.....	54
Görsel 7.8. ARIMA ile gelecek dönemlerde yapılan tahminler.....	54
Görsel 7.9. LSTM model mimarisi kodları.....	55
Görsel 7.10. LSTM kayıp grafiği.....	55
Görsel 7.11. LSTM tahmin test grafiği	55
Görsel 7.12. LSTM ile gelecek dönemlerde yapılan tahminler	56
Görsel 7.13. Hibrit formülünün Python karşılığı	56
Görsel 7.14. Hibrit karşılaştırma grafiği	57
Görsel 7.15. ARIMA, LSTM ve Hibrit Model, test verisi ile karşılaştırılması	57
Görsel 7.16. 2018 Ocak – 2020 Mart verileri	58
Görsel 7.17. Bitcoin, ARIMA, LSTM ve Hibrit model tahmin grafiği	59
Görsel 7.18. Django web portalı arayüzü.....	60
Görsel 7.19. Yüklenen veri setinin ekranı.....	61
Görsel 7.20. ARIMA tahmin ekranı.....	61
Görsel 7.21. LSTM tahmin ekranı	62
Görsel 7.22. Hibrit tahmin ekranı	62
Görsel 7.23. ARIMA manuel olarak parametreleri ayarlama ekranı	63
Görsel 7.24. LSTM manuel olarak parametreleri ayarlama ekranı.....	63
Görsel 7.25. Hybrid modelde ARIMA ve LSTM manuel olarak ayarlanması	64

SİMGELER VE KISALTMALAR DİZİNİ

ACF	: Oto Korelasyon
AIC	: Akaike Bilgi Kriteri
ANN	: Yapay Sinir Ağları
API	: Yazılım Programlama Arayüzü
AR	: Otoregresif
ARIMA	: Bütünleşik Otoregresif Hareketli Ortalama
ARMA	: Otoregresif Hareketli Ortalama
ART	: Adaptif Rezonans Teorisi Modelleri
CNN	: Konvolüsyon Sinir Ağı
DLSTM	: Gecikmeli Uzun Kısa Vadeli Bellek Ağları
DSS	: Karar Destek Sistemi
EKK	: En Küçük Kareler
GUI	: Grafik Kullanıcı Arabirimi
IACF	: Ters Oto Korelasyon
LSTM	: Uzun Kısa Vadeli Bellek Ağları
LVQ	: Vektör Kuantizasyon Modelleri
MA	: Hareketli Ortalama
MAD	: Ortalama Mutlak Sapma
MAPE	: Ortalama Mutlak Yüzde Hata
MDL	: Orta Tanım Genişliği
MLP	: Çok Katmanlı Algılayıcılar
MSE	: Ortalama Kare Hatası
PACF	: Kısmi Oto Korelasyon
PNN	: Olasılıksal Sinir Ağları
RBF	: Radyal Tabanlı Fonksiyonlar
RMSE	: Kök Ortalama Kare Hatası
RNN	: Tekrarlayan Sinir Ağlar
SARIMA	: Mevsimsel Bütünleşik Otoregresif Hareketli Ortalama
SARIMAX	: Mevsimsel Bütünleşik Otoregresif Hareketli Ortalama Eksojen
SOM	: Kendi Kendini Organize Eden Model

1. GİRİŞ

Zaman serileri üzerine tahmin modelleri geliştirmek, çeşitli bilim dallarının ilgili alanlarına girmektedir. Örnek olarak ekonomi, finans, mühendislik, sağlık ve meteoroloji gibi alanlarda tahmin sistemleri üretmek için sosyal, doğal, ekolojik ve finans gibi farklı olaylar tasarlanarak matematiksel modellere dönüştürülür. Ancak tahmin alanında yapılan çalışmalar ve modelleme alanında gelişmeler devam etmektedir. Tahmin sistemleri, olayları tatmin edici bir şekilde modelleyebilmede başarılı olsa da zamansal olaylarda açıklanamayan durumlar bu alanın önemli zorluklarını oluşturmaktadır (Box, Jenkins, Reinsel, & LJung, 2016).

Literatürde, zaman serileri üzerine istatistiksel yöntemler ve ANN (Yapay Sinir Ağları) birlikte kullanılarak birçok alanda başarılı tahmin uygulamaları geliştirilmiştir (Panigrahi & Behera, 2017). ARIMA (Bütünleşik Otoregresif Hareketli Ortalama), AR (Otoregresif) ve MA (Hareketli Ortalama) modelleri tahminleme çalışmalarının çeşitli alanlarında kullanılmıştır (Box, Jenkins, Reinsel, & LJung, 2016). Bu istatistiksel yöntemler basit ve esnektir. Çeşitli zamansal olayları modellemek için parametrelerinde değişiklikler yapılarak kullanılabilir (Faruk , 2010). AR, MA ve ARIMA tamamen doğrusal modellerdir ve bu nedenle gerçek dünya zamanında sınırlı bir performans sunmaktadırlar (Zhang G. , 2003). Yaygın olarak doğrusal ve doğrusal olmayan zaman serilerini modellemede kullanılırlar (Firmino, Neto, & Ferreira, 2015).

ANN (Yapay Sinir Ağları) doğrusal olmayan olayları modelleme konusunda doğruluk açısından oldukça iyi sonuçlar vermektedir (Zhang, Patuwo, & Hu, 1998). ANN, doğal yapısı gereği zaman serilerinde doğrusal olmayan olayları modelleyebilir. Bunu verilerin üzerinde bilinmeyen bağlantıları ortaya çıkarmak ya da diğer bir deyişle öğrenme sürecine dayalı olarak yapar. ANN öğrenme süreci, temelinde zamansal olayların ilişkisini tahmin etmek amacıyla geçmiş gözlemleri modellemektedir (Neto, Ferreira, Lima, Vasconcelos, & Cavalcanti, 2017). Literatür incelemesi sürecinde, gerçek dünya zaman serisi tahmininde, tek bir ANN'nin benimsenmesi, modelin yanlış tanımlanması, yetersiz verinin veya aşırı eğitim verisinin olması ile ilgili sorunlar nedeniyle hem doğrusal hem de doğrusal olmayan modellerin eşit derecede modellenmesi için yeterli olmayabileceği gözlenmiştir. ANN'nin yukarıda bahsedilen kısıtları sebebiyle, bu kısıtlar ile başa çıkmak üzere farklı mekanizmalara sahip olan LSTM yöntemi seçilmiştir. LSTM zaman serisi verilerinde doğrusal olmayan örüntüleri

yakalama yeteneğinden kaynaklı olarak ve de performans olarak diğer ANN yöntemlerine göre avantaj farklı çalışmalarda göstermiştir (Abbasimehr, Shabani, & Yousefi, 2020).

Bu çalışmada, klasik istatistiksel modelleri ve ANN'leri birleştiren hibrit model üzerinde bir karar destek sistemi geliştirilmiştir. Hibrit model mimarisi, tüm sistemin performansını arttırmak için seçilmiştir (Faruk , 2010). Literatürde Wongsatha ve Seedadan (2016) tarafından yapılan incelemelerde istatistiksel modelleri ve ANN'leri birleştiren hibrit modelde hata oranının düştüğü gözlemlenmiştir. Zaman serilerini modellemek için farklı teknikleri birleştiren hibrit modeller, zaman serisinin doğrusal ve doğrusal olmayan yapılarını modelleyerek farklı teknikleri birleştirdiği için doğru modelin seçimini ve problemlerin daha başarılı olarak çözümlerini sağlamaktadır (Khashei & Bijari, 2010).

Doğrusal ve doğrusal olmayan modellerin birleşimi genellikle örüntüler arasında doğrusal bir ilişki olduğunu varsaymaktadır (Oliveira & Ludermir, 2016). Hibrit modellerin bir dezavantajı doğrusal ve doğrusal olmayan zaman serileri arasında bağ olmaması durumunu göz ardı etmesidir (Zhang G. , 2003). Literatürde Khashei ve Bijari (2010) tarafından önerilen ikinci varsayımında ise, doğrusal ve doğrusal olmayan bileşenler arasında doğrusal olmayan bir kombinasyon olduğu varsayımını yapmaktadırlar. Bu varsayımı izleyen çalışmalarda doğrusal olmayan modelleme yapmak için makine öğrenmesinin yöntemleri kullanılmıştır. Khashei ve Bijari (2011) ve Zhu ve Wei (2013) zaman serilerinde doğrusal olmayan modelleme yöntemleri ile nihai tahmini üretmişlerdir. Genel olarak, zaman serilerinde doğrusal olmayan yaklaşımlar doğrusal yaklaşımlara göre daha iyi sonuçlara ulaşmaktadırlar. Bununla birlikte doğrusal olmayan bir yaklaşımın zaman serileri üzerinde her zaman en uygun modelleme yöntemi olduğunu söylemek mümkün değildir. Bu nedenle hibrit bir modelin seçimi zorlaşmaktadır ancak hibrit modelle üretilcek tahminler tatmin edici sonuçlar vermektedir (Khashei & Bijari, 2011).

Zhang (2003) çalışmasında ARIMA ve ANN'nin birleşiminden bir hibrit model geliştirmiştir. Geliştirmiş olduğu hibrit modeli zaman serileri üzerinde uygulamıştır. Zhang'ın çalışmada kullandığı zaman serileri Wolf'un güneş lekesi verileri, Kanada vahşi kedi verileri ve İngiliz sterlini - ABD doları döviz kuru verileridir. Zhang çalışmasında, ARIMA ve ANN modellerinin tek başlarına zaman serilerinin yapısı gereği doğrusal ve doğrusal olmayan örüntüler içerdiği için uygun olmadığını açıklamıştır. Zaman serilerinin

tahmininde hibrit bir modelin kullanımının doğrusal ve doğrusal olmayan yapıları modelleme avantajı oluşturacağını, bu nedenle çalışmada zaman serileri için hibrit bir modelin tercihinin doğru olacağını göstermiştir.

Khashei, Hejazi ve Bijari (2008) çalışmasında ANN ve bulanık regresyon yöntemlerini birleştirmiştir. Eksik veriler olsa bile doğruya daha yakın sonuç veren hibrit bir model geliştirmiştir. Çalışmanın etkinliğini göstermek açısından altın fiyatı (Gram/US \$) ve döviz kuru (US \$/İran Rials) üzerinde tahmin yapmıştır. Modelin tahmin doğruluğunun artış sağladığı saptanmıştır.

Aladag, Eğrioğlu ve Kadılar (2009) çalışmasında RNN (Tekrarlayan Sinir Ağları) ve SARIMA (Mevsimsel ARIMA) modellerinin birleşiminden yeni bir hibrit model yaklaşımı önermiştir. Önerilen modelde 1821-1934 dönemini kapsayan Kanada hayvan tuzakları veri seti olarak kullanılmıştır. Çalışmada kullanılan verilerin sınırlı olmasına karşılık, önerilen hibrit model tahmin üretmeyi başarmıştır.

Koutroumanidis, Ioannou ve Arabatzis (2009) ARIMA, ANN ve hibrit bir model kullanarak Yunanistan'da odun üretimini incelemişler ve üretilen odunların satış fiyatlarını tahmin etmeye çalışmışlardır. Koutroumanidis, Ioannou ve Zafeiriou (2011) başka bir çalışmada ARIMA ve LSTM modellerinden oluşan hibrit yöntem üzerinden borsa fiyat tahmini yapmışlardır. Çalışmada Alpha Bank hisselerinin 28/01/2004 - 30/11/2005 döneminin kapanış fiyat verileri üzerinden Bootstrap yöntemi kullanımı ile hisse fiyatını tahmin etmişler ve tahmin doğruluğu belirledikleri kriterler doğrultusunda tatmin edici sonuçlar vermiştir.

Papagera, Ioannou, Zaimis, Iakovoglou ve Simeonidou (2014) çalışmalarında hibrit bir model kullanarak MIKE, SHE ve ANN'nin birleşiminden su seviyesini tahmin etmişler ve bu çalışmada 2008-2012 yılları arasında Yunanistan'da bulunan Koronia Gölü su seviyesi verilerini kullanmışlardır.

Babu ve Reddy (2014) yaptıkları çalışmada güneş lekesi, elektrik fiyatı ve borsa verileri gibi deneysel tasarım için hazırlanmış veri setlerini kullanarak oynaklığın doğasını (nature of volatility) araştırmışlardır. İlk adımda MA filtresi uygulanmış, sonrasında ise ARIMA ve ANN ile birlikte hibrit model uygulanmıştır. Çalışmada önerilen hibrit model bazı hibrit modellerle birlikte uygulanmıştır. Elde edilen sonuçlar

incelendiğinde hem tek hem de çok aşamalı uygulamalarda hibrit modellerin başarı tahmin yüzdesine sahip olduğunu göstermektedir.

Hocaoğlu, Kaysal K. ve Kaysal A. (2015) çalışmalarında ANN ve regresyon birleşiminden oluşan hibrit bir model ortaya koymuşlardır. Ortaya koydukları modelle enerji sektöründe yük tahmini yapmışlardır. Hata sonuçları karşılaştırıldığında hibrit modelin daha az hataya sahip olduğu gözlemlenmiştir.

Pablo ve arkadaşları (2016) çalışmalarında zaman serileri üzerinde ANN ve Monte Carlo Simülasyon yönteminin birleşiminden hibrit bir model önermişlerdir. Hibrit model yaklaşımı ile süt üretimi yapan bir işletmenin süt satışını tahmin etmeye çalışmışlardır. Çalışmada ortaya çıkan sonuçlar doğrultusunda, geçmişin yeniden yapılandırılması ile geleceğe yönelik tahmin yaparken başarılı sonuçlar elde edilmiştir.

Sugiartawan, Pulungan ve Sari (2017) çalışmalarında Endonezya'ya gelen turist sayısının tahmini için LSTM ve dalgacık dönüşüm birleşiminden hibrit model yaklaşımı ortaya koymuşlardır. Ortaya konulan hibrit model yaklaşımını, farklı hibrit model yaklaşımları ile kıyaslamışlardır. Elde edilen tahmin sonuçları doğrultusunda turist sayılarında başarılı sonuçlar gözlemlenmiştir. Diğer hibrit yaklaşımlarla kıyaslandığında ise MSE hatasının oldukça düşük olduğu sonucuna varılmıştır.

Lin, Guo ve Aberer (2017) çalışmalarında Yapay Sinir Ağlarının zaman serilerini tahmin etme doğruluğu nedeniyle yeni hibrit bir yaklaşım olarak TreNet'i ortaya koymuşlardır. Bu yaklaşım zaman serilerinde trend gelişimini ortaya çıkarmıştır ve bu alanda kullanılan yaklaşımlarla kıyaslandığında önemli derecede doğruluk oranında artış sağlamıştır. Kullanılan veri setleri Yahoo Finance ve New York Borsası'nda günlük borsa bilgilerinden hazırlanmıştır.

Yu, Jiao, Xin, Wang ve Wang (2018) çalışmalarında ikinci el konut fiyatlarının tahmini için CNN (Konvolüsyon Sinir Ağı), LSTM ve ARIMA'dan oluşan bir hibrit model ortaya koymuşlardır. Ortaya çıkan sonuçların karşılaştırılması için regresyon modeli uygulanmıştır. Elde edilen sonuçlarda zaman serilerinin tahmininde LSTM'nin doğruluk açısından diğer yöntemlere göre daha başarılı sonuçlar verdiğine kanaat getirilmiştir.

Choi (2018) çalışmasında hisse senedi korelasyonu katsayısının tahmini için ARIMA ve LSTM'den oluşan bir hibrit model yaklaşımı ortaya koymuştur. Önerilen

modelin performansını karşılaştırmak adına geleneksel finansal modeller ile karşılaştırılmıştır. Bulgularının doğrultusunda hibrit bir modelin üstünlüğü kanıtlanmıştır.

Baughman, Haas, Wolski, Foster ve Chard (2018) çalışmalarında Amazon'un bulut sunucusu kapasitesi için arz ve talebe dayalı dalgalanan piyasa için spot fiyat tahmini üretmeye çalışmışlardır. Çalışmanın üç katmanlı bir LSTM modeli ile ARIMA modeli kullanılmış ve modellerin karşılaştırması yapılmıştır.

Sagheer ve Kotb (2019) çalışmalarında DLSTM (Gecikmeli Uzun-Kısa Süreli Bellek) modelini kullanarak petrol sahasında üretim verileri üzerine tahmin üretmişlerdir. Önerilen model farklı modellerle karşılaştırılmış ve de modelin daha iyi performans gösterdiğine karar vermişlerdir.

Xu ve arkadaşları (2019) çalışmalarında zaman serilerinin tahmini için doğrusal regresyon ve derin öğrenme modellerinin birleşiminden hibrit bir yaklaşım ortaya koymuşlardır. Bu hibrit yaklaşım için diğer hibrit modeller ile karşılaştırma yapmıştır. Yaptığı karşılaştırmalar sonucunda öneride bulunduğu hibrit modelin zaman serileri tahmininde etkili bir araç olarak kullanılabileceğini önermektedir.

Su ve arkadaşları (2019) çalışmalarında dalgacık dönüşümü ve LSTM'i birleştirerek hibrit bir yaklaşım üzerinden gaz fiyatlarını saatlik bazda tahmin etmeye çalışmışlardır. Algoritmanın evrimleşmesini sağlamak için hibrit modele genetik algoritma eklemişlerdir. Performans ölçmek için modeli farklı saat aralıkları ile tahmin oranını karıştırmışlardır. On saatten sonrasında performansında ciddi düşüşler olduğu görülmüştür. Sonuçlar başka hibrit modellerle karşılaştırılmıştır. Elde edilen bulgular doğrultusunda RNN modellerinin kısa vadeli tahminlerde doğruluk oranının arttığı gözlemlenmiştir.

Rhanoui, Yousfi, Mikram ve Merizak (2019) çalışmalarında bütçe zaman verilerini tahminlemek için ARIMA Random Walk ve LSTM yöntemlerini karşılaştırmışlardır. Elde edilen sonuçlarda LSTM ağırlıklı olarak daha iyi performans sergilediği görülmüştür.

Temür A.S., Akgün ve Temür G. (2019) çalışmalarında Türkiye'deki eve satış fiyatlarının tahminlemesi adına ARIMA ve LSTM yöntemleri birleştirilmesinden hibrit bir model yaklaşımı önermişlerdir. Önerilen yaklaşımda TÜİK'ten elde edilen veriler ile

performans deęerlendirmesi adına MSE ve MAPE kriterleri dikkate alınmıřtır. Elde edilen sonular doęrultusunda ARIMA ve LSTM modelleri ile hibrit model karřılařtırılmıřtır. Hibrit model arpıcı bir řekilde stn performans sergilemiřtir.

Bu alıřmanın ıktısı olarak yardımcı bir karar destek sisteminin geliřtirilmesi hedeflenmiřtir. Karar destek sisteminin veri bileřeni olarak alıřmaya konu olan iřletmeden elde edilen satıř verileri kullanılmıřtır. Geliřtirilen karar destek sistemi, bařarılı tahminler yapabilmek adına tahminleme ile ilgili ileri dzey modeller ierdięi iin, model ynelimli olarak adlandırılmaktadır.

alıřmanın temel motivasyonlarından bir tanesi, ele alınan iřletmede sezgisel olarak gerekleřtirilen talep tahminlerinin, ileri tahmin modelleri kullanan bir karar destek sistemine dnřtrlmesidir.

DSS Python ortamında Django 3.0 ve Python 3.7 ktphaneleri kullanılarak oluřturulmuřtur. Bu ktphaneler model ve veri ynetimi iin olduka kullanıřlı aralar sunmaktadır. DSS'nin arayzleri iin ise web tabanlı arayzler olarak geliřtirilmiřtir.

Uygulama probleminde tahmine konu olan rnlerin seiminde ABC analizi kullanılmıř ve bu rnler ile ilgili verilerin modeller zerinde kullanılabilmesi iin bazı veri n iřlemleri gerekleřtirilmiřtir.

alıřma kapsamında ikinci blmde talep tahmini, nc blmnde makine ęrenmesi, kavramları ve kullanılması planlanan yntemler incelenmiřtir. Drdnc blmde zaman serilerinin yapısı, beřinci blmde hibrit kavramı, hibrit modeller ve uygulamada kullanılan hibrit (ARIMA ve LSTM) model ayrıntılı bir řeklide aıklanmıřtır. Altıncı blmde karar destek sistemleri kavramına, eřitlerine ve uygulama srecinde kullanılan karar destek sistemine yer verilmiřtir. Yedinci blmde uygulama srecinde kullanılan karar destek sistemi yapısı iin veri tabanı, model tabanı ve arayzleri hakkında detaylı bilgi aktarılmıřtır. Sonu blmnde bulgular ve deęerlendirmeler yapılmıřtır.

2. TALEP TAHMİNİ

2.1. Talep Tahmini Kavramı

Tüketicilerin belirli bir fiyat aralığından bir mal veya hizmeti satın alma isteğine talep denir. Tahmin, bilinmeyen bir parametrenin değerinin, bilinen parametreler kullanılarak, gelecekteki durumun öngörülmesidir. Talep tahmini kavramı ise, tüketicilerin gelecek dönemlerde bir mal veya hizmete olan talebinin tahmin edilmesi işlemidir (Karaatlı, Helvacıoğlu, Ömürbek, & Tokgöz, 2012).

Bazı işletmeler talep tahmini yerine satış tahminine ihtiyaç duymaktadır. Etkin bir talep planlama ile şirket fonksiyonları optimum kar seviyesine doğru ilerler ve stratejik hedefler ile operasyonel gereksinimler arasındaki çatışma azalır (Adıyaman, 2007). Ürün ve hizmetin fiyatı, tüketicilerin gelir seviyeleri, ihtiyacın şiddeti, tüketici alışkanlıkları, mevsimsel etkenler talep tahminini etkileyen faktörler arasında sayılabilir (Yazıcıoğlu, 2010).

Talep tahmini yapılırken, gelecek dönemlerde gerçekleşecek durumlar için bir değişkene ait geçmiş dönemlerde elde edilen verilerden yararlanılır. Günümüzde işletme yöneticileri, stratejik kararlar ile geleceğe dönük planlamalarını sağlıklı bir şekilde gerçekleştirmek için başarılı tahminleme yapmak zorundadır (Karahan, 2011).

Gerçekleştirilecek tahmin çeşidi ve etkileyeceği zamanı, ürün özellikleri ve talep türleri etkiler. Eğer ürüne olan talep genel olarak sabit ise, tahminin zaman süresi biraz daha kısa tutulabilir. Tahmin en az bir dalgayı kapsayacak dönemi içeriyorsa, ürüne olan talepte dalgalanmalar vardır. Talepte uzun dönemde bir eğilim bekleniyorsa, daha uzun dönemli bir tahmin yapmak gerekir. Bazı ürünler için talep değerleri mevsimlere göre azalır veya çoğalır. Böyle durumlarda ise talepteki mevsimsel değişimlerin nedenini iyi belirlemek ve mevsimsel tahmin yöntemlerini kullanmak gerekir (Yazıcıoğlu, 2010).

Bunun sonucunda talep tahminlerinde dikkat edilmesi gereken ilkeler şöyle açıklanabilir:

- Miktar veya çeşit bakımından büyük olan gruplar için yapılan tahminler daha duyarlıdır. Ürün veya hizmet çeşitliliği arttıkça birçok değişiklik ortaya çıkmaktadır. Ortaya çıkan değişiklikler varılacak nihai sonucun güven aralığının değişken olmasına ve tahminlerin farklılık göstermesine neden olmaktadır.

- Zaman aralığı kısaltıldıkça talep tahminlerinin doğruluğu artar. İşletmenin dört yıllık satış analizi, dokuz yıllık satış analizinden daha doğrudur.
- Her talep tahmin araştırmasında sapmaları belirleyecek bir hata oranı belirlenmelidir. Talep tahmini yapılırken kullanılan analiz yöntemine değerlendirme sürecinde belirlenen aralıkta standart sapma uygulanır.
- Talep tahmin araştırmasının sonuçlarını uygulamaya geçmeden önce kullanılan yöntemin doğruluğu test edilmelidir. Test aşamasında ortaya çıkan bir takım hataları ve sapmaları düzeltmek üzere gerekli tedbirler alınır.

2.2. Talep Tahmini Aşamaları

Talep tahmini temel olarak beş aşamada gerçekleştirilir. Bu aşamalar aşağıdaki şekildedir:

1. Talebi Etkileyen Etkenlerin Belirlenmesi:

Talep tahmini yapılırken işletmenin geçmiş işlemlerinin zaman kaydının, mali kayıtlarının tutulmuş olması geleceği tahmin ederken doğruluğunu arttırmaktadır. Bu aşama talep tahmini için çok önemlidir çünkü yapılan tahminin geçerliliğini ve değerini gösterir. Talep tahmini sonucu ulaşmak istediği amaç doğrultusunda tahmin için gerekli kapsama ve ayrıntılarına karar verir (Karahana, 2011). Talep tahmini yapmadan önce kuruluşun hangi çevre ortamında bulunduğu, hangi ürünleri sattığı, tahmini yapılacak ürünün özellikleri, kuruluşun şimdiki durumu ve gelecekte ulaşmak istediği hedefi, rakiplerin durumu, fiyat ve talep ilişkisi, iktisadi değişimler, endüstriyel değişimler, teknolojik gelişim, sosyal değişimler, ulusal ve uluslararası eğilimler gibi talebi etkileyen etkenler ve ağırlıkları belirlenmelidir (Adıyaman, 2007).

2. Verilerin Toplanması:

Talep tahminini etkileyecek etkenler göz önünde bulundurularak veriler toplanır. Veri olarak genellikle geçmişte gerçekleşen veriler, istatistiksel olasılıklar ve hedef veriler kullanılır. Verilerin derlenmesinde iç kaynaklar, şirket tarafından yapılan anket ve tahmin araştırması, yayınlanmış istatistik verileri, yayınlanmış anketler ve iktisadi veriler kullanılabilir (Adıyaman, 2007). Talep tahmini yaparken belirlenen hedef göz önüne alınarak toplanacak verilerin cinsi, içeriği ve ayrıntısı konusunda doğru karar verilmesi

gerekir. Eksik veya istenilenden daha ayrıntılı veriler, araştırmanın maliyetini ve süresini arttırdığı gibi, sonuçların doğruluğunu da olumsuz yönde etkiler (Yazıcıoğlu, 2010).

3. Talep Tahmin Periyodunun Tespiti:

Talep tahmin araştırması sonuçlarının kullanılış amacı ile periyodun uzunluğu arasında yakın bir ilişki vardır. Yapılan çalışmalar kısa süreli yapılan tahminlerin kısa dönemlerde, uzun süreli yapılan tahminlerin ise uzun dönemlerde daha iyi sonuçlar verdiğini göstermektedir. Örneğin, haftalık yapılan satışların belirlenmesinde yararlanılan tahminlerin aylık satış tahmininde kullanılması sonuçların doğruluğunu etkilemektedir. Bu etkinin nedeni, haftalık verilerdeki değişim kaynağının aylık verilerdeki değişim kaynağına göre farklı olmasıdır (Karahan, 2011).

4. Talep Tahmin Yönteminin Seçimi ve Hata Oranı:

Talep tahmininde uygulanacak yöntemin seçiminde amaç doğrultusunda bilgilerin toplanması, toplanan bilgilerin değişkenlik, duyarlılık gibi kriterlerine bu aşamada dikkat edilmesi gerekir. Toplanan bilgiler duyarlı olmadığında çok detaylı sonuçlar veren talep tahmin yöntemleri kullanılmamalıdır. Detay gerektirmeyen talep tahmin süreçlerinde gereksiz detaya giren incelemeler, araştırmanın amacını kaybetmesine neden olabilir. Belirtilen bu hususlarda hata oranı hesabı yapılırken de dikkat edilmesi gerekmektedir. Bir tahminin doğruluğu, tahmin edilen değerler ile gerçekleşen değerler arasındaki farktır. Bu farka hata denir. Talep tahminin doğruluğu, ön yargılı olmaması (sapmasız) ve tutarlı olmasıdır. Ön yargısız bir talep tahmini, ortalama sıfır sapmaya sahiptir. Toplanan tüm bilgilerin talep tahminine yansması, araştırmacının etkili bir talep tahmini yaptığını gösterir (Ballı, 2014).

5. Talep Tahmin Sonuçlarının Geçerliğinin Araştırılması:

Talep tahmin sürecinde toplanan bilgilerin doğruluğu tahminin geçerliliğini önemli ölçüde etkilemektedir. Belirlenen talep tahmin sonuçlarının gerçek değerlerle karşılaştırılması ve bu farklılığın neden oluştuğunun araştırılması sürecidir.

2.3. Talep Tahmininde Kullanılan Yöntemler

Tüketicinin isteklerine zamanında karşılık vermek amacıyla stoklamaya gidilmesi talep tahminlerinin önemini daha da artırmaktadır. Talep tahmininin kapsadığı zaman

aralığı büyüdükçe sonucu etkileyen faktörlerin sayısı artar ve bunlar arasındaki ilişkiler gittikçe karmaşık bir hal alır. Doğru bir tahmin için her detayı önemsemek gerekir. Buna karşılık vade kısaldıkça tahminlerin gerçeğe uygunluk derecesi de artar (Karahan, 2011).

Talep tahmininde kullanılan yöntemler, sayısal ve yargıya dayalı olarak iki ana başlık altında toplanır. Yargıya dayalı yöntem türleri uzmanların bilgi ve deneyimine bağlı görüşlerin yer aldığı bir yöntem olup, bu alandaki gelişmelerin ne yönde olacağı, ne tür ihtiyaçlar ortaya çıkaracağı gibi konularda yoğunlaşmaktadır. Sayısal yöntemler ise matematiksel modellere dayanan, yeterli miktarda sayısal verinin mevcut olduğu durumlarda kullanılır (Karaatlı, Helvacıoğlu, Ömürbek, & Tokgöz, 2012). Verilerin sayısal olarak iyi bir şekilde düzenlenip analiz etmeye hazır duruma getirilmesi, bu yöntemlerin temelini oluşturmaktadır (Yazıcıoğlu, 2010).

2.3.1. Yargıya dayalı yöntemler

Yargıya dayalı yöntemler, çalışma alanı konusunda uzman kabul edilen kişilerin düşüncelerine ve deneyimlerine dayanmaktadırlar. Bu yöntemlerde bilgi işleme süreci uzmanlar veya jüri üyeleri tarafından gerçekleştirilir (Yazıcıoğlu, 2010). Çalışanların deneyimlerini ve anketleri esas alan, bununla birlikte basit matematiksel çözümler de kullanarak farklı tahmin yöntemleriyle de birleştirilebilen yöntemlerdir. Yargıya dayalı yöntemler genellikle geçmiş verilerin yetersiz olması durumunda kullanılırlar. Yeni bir ürün ya da hizmetin piyasaya sürülmesi, bir ürünün paketinin değişmesi ya da gelecek talep tahminin politik ya da teknolojik nedenlerden dolayı etkilenmesi durumları örnek verilebilir (Saatçioğlu, 2016).

Yargıya dayalı yöntemler, kişilerin beklentilerini ifade etmeleri ve subjektif düşüncelere bağlı olmaları nedeniyle tekrarlanmayan ve sonuçları tartışmaya açık yöntemlerdir. Aşağıda belirtilen koşullar bu yöntemlerin kullanılmalarını zorunlu hale getirmektedir:

- Geçmişe yönelik yeterli verinin bulunmaması
- Mevcut zaman serilerinin güvenilir ya da geçerli olmaması
- Makro çevrenin çok hızlı bir şekilde değişmesi
- Çevresel etkiler açısından büyük karışıklıklar beklenmesi
- Uzun dönem tahminlerine ihtiyaç duyulması (Yazıcıoğlu, 2010)

Yargıya dayalı yöntemlerin avantajları şunlardır:

- Yöntemlerin ileri düzeyde istatistiksel yeteneklere ihtiyaç duymamaları ve ucuz olmalarıdır.
- Kişilerin karşı karşıya gelmelerinden kaynaklanabilecek problemler en aza indirgenmektedir. Bu şekilde kişiler, diğerlerinin baskısına maruz kalmadan düşündüklerini özgürce ifade edebilmektedirler.
- Katılımcılar, ardışık anketler vasıtasıyla edinilen geri bildirimler sonucunda, farklı düşüncelerle ilgili bilgi sahibi olmaktadır. Böylece, kendi düşüncelerini gözden geçirme ve değerlendirebilme imkanına sahip olmaktadır.

Yargıya dayalı yöntemlerin dezavantajları şunlardır:

- Başarının, jüri veya uzmanların seçimlerine bağlı olması
- Jüri veya uzmanların deneyimlerinin yetersizliği
- Sonuçların geri bildiriminin zaman alması
- Sürecin uzaması ile birlikte katılımın azalması

(Yıldırım, 2019)

Senaryo analizi

Senaryo geliştirmek, yaratıcılık isteyen bir faaliyet olup, asıl amaç sonuca ulaşma yolunda "birden fazla" sayıda muhtemel durum geliştirmek, bunlara uyumlu davranışları belirleyebilmektir (Yıldırım, 2019). Senaryolar gelecek için alternatifler ortaya koymakta ve ekonometrik modellerin dışarıda bıraktığı konuları ve niteleyici perspektifleri de içine almaktadır. Senaryolar, geleceğe ait muhtemel gelişmeleri dikkate alarak daha net bir görüş açısı sağlayabildiği gibi nelerin olabileceğini veya olanların ne olduğunu anlamaya yardımcı olmaktadır. Senaryo analizinde önemli olan, tüm senaryoların karar vericiye olası durumlar içinde kendi içinde bulunduğu durumdan bir başkasına geçişinde belirli bir yol önerebilmektir (Yazıcıoğlu, 2010).

Uzman panel

Uzman panel yöntemi, oluşturulan bir panel aracılığı ile üyelerin çoğunluğunun onayladığı bir sonuca ulaşmayı hedeflemektedir. Uzman panel yönteminin delphi yönteminden farkı, panel üyelerinin bir araya gelerek konu hakkındaki görüş ve düşüncelerini karşılıklı belirtme ve fikir alışverişinde bulunmasıdır. Bu nedenle teknik

üyelerin etkileşiminin iyi olduğu gruplarda daha çok kullanılır. Çalışma süreci panel üyelerinin görüş birliği sağlaması ile sona ermektedir. Panel üyeleri konusunda uzman, farklı görüş ve deneyimlere sahip kişiler arasından seçilmelidir. Bu kişilerin ele alınan konudan uzak olmaları konuya tarafsız yaklaşımlarını sağlayacağından daha yapıcı fikirlerin ortaya çıkmasını sağlayabilmektedir (Yazıcıoğlu, 2010).

Uzman panel yönteminin avantajları; geçmişe dayalı veriler kullanarak kısa sürede hazırlanarak her ortamda uygulanabilir. Uzman panel yönteminin eksik yönü toplam tahmini yansıtmamasıdır (Yıldırım, 2019).

2.3.2. Sayısal yöntemler

Sayısal yöntemler, geçmiş dönem gerçekleşen verilerine dayalı analizler yapan tahmin modellerini kapsamaktadır. Kullanılan yöntemler; incelenen değişkende gözlenen gelişmelerin analiz edilmesi, veri serisinin dinamik özelliklerinin belirlenmesi ve bu özelliklerin matematiksel çözümler ile ifade edilerek geleceğe ilişkin öngörülerin türetilmesini içermektedir (Yazıcıoğlu, 2010).

Yargıya dayalı ve sayısal yöntemlerin, ayrı ayrı kullanıldığı gibi her iki yaklaşımın birlikte kullanılması da mümkündür ve genellikle en verimli sonuçları verir.

Nedensel modeller

Neden - sonuç ilişkisine dayalı tahmin ile bağımlı değişkenler arasındaki bağlantıya göre kullanılan analizlerdir. Bağımlı ve bağımsız değişkenler arasında güçlü istatistik çıkarımlarla tahmin yapılmasına destek olmaktadır.

Basit regresyon analizi

Regresyon analizi, aralarında sebep - sonuç ilişkisi bulunan herhangi iki değişken (bağımlı değişken, bağımsız veya açıklayıcı değişken) veya daha fazla değişken arasındaki ilişkiyi belirlemek ve bu ilişkiyi matematiksel fonksiyon kullanarak tahminler yapabilmektedir (Yazıcıoğlu, 2010). Bağımlı değişkeni etkileyen bağımsız değişkenlerin tahmin edilmesi, bu değişken üzerinde geleceğe yönelik stratejilerde hangi değişkenlerin önem kazandığının belirlenmesine destek olmaktadır (Karahan, 2011). Tahminleme sürecinde bağımsız değişkenlerin verileri sıra dışı ise tahmin hatası fazla olmaktadır. Geçmiş dönem verileri düzenli ve sürekli ise tahminin tutarlılığı yüksektir (Ballı, 2014).

Aşağıdaki yer alan basit regresyon analizinin a , b değerlerini bulmak için EKK (En Küçük Kareler) yöntemi kullanılır.

$$y = a + bX \quad (2.1)$$

Korelasyon analizi

Korelasyon analizi, iki değişken arasındaki ilişkinin derecesini ifade etmektedir. İlişki ne kadar güçlü ise yapılan tahminlerin doğruluğu o derece artmaktadır. Basit korelasyon, iki değişken arasındaki ilişkinin yakınlığını korelasyon katsayısı cinsinden ifade etmektedir. Korelasyon katsayısı (r) ile gösterilmektedir ve iki değişken arasındaki ilişkinin derecesini ifade eder (Ballı, 2014).

Korelasyon katsayısı (r), -1 ile +1 arasında herhangi bir değer almaktadır. Basit regresyon analizi denkleminde yer alan x ve y değerleri beraber artıyorsa pozitif; x arttığında y düşüyorsa negatif bir değer alır. x ve y değerleri arasında ilişki bulunmaması durumunda $r = 0$ değerini alır.

Tablo 2.1. *Korelasyon katsayısı değerleri ve yorumlamaları*

Korelasyon Katsayısı Değerleri	Yorumlamaları
0,90 – 1,00	Çok yüksek korelasyon
0,70 – 0,90	Yüksek korelasyon
0,40 – 0,70	Normal korelasyon
0,20 – 0,40	Düşük korelasyon
0,00 – 0,20	Çok düşük korelasyon

Tablo 2.1’de görüldüğü üzere korelasyon katsayısı değerlerinin 1’ye yaklaşması yüksek (güçlü) korelasyon ilişkisinin olduğunu göstermektedir. Korelasyon katsayısının 0’a yaklaşması düşük (zayıf) korelasyon ilişkisinin olduğunu göstermektedir.

Yapay sinir ağları modelleri

ANN (Yapay Sinir Ağları) kavramı, insan beyninin çalışma prensiplerinin bilgisayar ortamında taklit edilme fikriyle ortaya çıkmıştır. İlk çalışmalar beynimizdeki nöronların matematiksel şekilde modellenmesi üzerine yoğunlaşmıştır (Yıldırım, 2019). ANN, girdi - çıktı ilişkisinde karmaşık modelleme gücüne sahip önemli yöntemler arasında yer almaktadır. ANN modelleri, birbirine bağlı nöronlara atanmış ağırlıklarla analizlerini gerçekleştirir ve genel olarak girdi katmanı, gizli katman ve çıktı katmanından

oluşur (Kayhan, 2019). ANN modelleri, araştırmanın 3. bölümünde detaylı olarak anlatılmıştır.

Zaman serisi modelleri

Zaman serisi modellerinde, geçmiş veriler incelenerek belirli bir eğilim olup olmadığı belirlenerek, gelecekle ilgili talep tahmin işlemi yapılmaya çalışılır. Geçmişe yönelik verilerin zaman içindeki değişimini gösteren bir dizi veri, bir zaman serisi oluşturur. Zaman serisi analizi ile bu verilerin değişim biçimi araştırılır ve sürecin davranışını temsil eden bir model kurulur. Bu model kullanılarak, geleceğe yönelik talep tahmini yapılır. Zaman serisi modellerinin kurulabilmesi için zaman serisinin davranışını biçimlendiren beş etmen bilinmelidir:

- Ortalama: Veriler, ortalama bir değer çevresinde gerçekleşmektedir.
- Eğilim (Trend): Veriler sürekli artma veya azalma eğilimi gösterirler. Sürekli olarak aynı yönde değişen bir eğilimin, bir doğru veya eğri ile temsil edilmesi, zaman serisinin modelini kurmak için gerekli ilk adımdır. Doğrunun/eğrinin fonksiyonu bilindiğinde, gelecekteki bir zamana ilişkin talep değeri kolayca hesaplanabilir.
- Mevsimlik Değişim: Verilerin mevsimsel dönemlerde artması veya azalmasıdır.
- Periyodik Değişim: Verilerin mevsimsel değişimler dışındaki daha uzun vadeli değişimleridir. Uzun dönemlere yayılan talep dalgalanmalarını gösteren değişim olarak da düşünülebilir.
- Rastgele Olaylar: Düzensiz ve anlaşılması kolay olmayan rastgele olaylardır (Yazıcıoğlu, 2010).

Zaman serileri hakkında detaylı bilgiye 4. bölümde yer verilmiştir.

Üstel düzeltme yöntemi

Üstel düzeltme yöntemi, ağırlıklı ortalama sistematığını dikkate alan bir tahmin yöntemidir. Geçmiş dönem verilerine eşit ağırlıklar veren basit hareketli ortalamalar yöntemine benzemesine rağmen; geçmiş dönem verilerine eşit olmayan, farklı ağırlıkların verildiği yöntemler topluluğudur. Üstel terimi, verilen ağırlıkların veriler eskidikçe üstel bir şekilde azalması anlamına gelir. Yani, tahminde kullanılan geçmiş dönem

verilerinden yakın zamanda olanlara yüksek üstel değerler, eski dönemdekilere de düşük üstel değerler verilerek uygulanır (Ballı, 2014).

Her yeni tahmin, bir önceki tahmin ile tahminin ve gerçekleşen değer arasındaki farkın yüzdesinin toplamına eşittir. Aşağıdaki şekilde göstermek mümkündür:

$$\text{Bir sonraki tahmin} = \text{Bir önceki tahmin} + \alpha (\text{Gerçekleşen} - \text{Bir önceki tahmin})$$

Denklemden yer alan (Gerçekleşen – Bir önceki tahmin) bölümü tahmin hatasını temsil etmektedir. Düzeltme katsayısı α değeri ifade edilmektedir. α değeri 0 ile 1 arasında bir değer almaktadır. Düzeltme katsayısı geçmiş verilerin etkisini düzenli hale getirmektedir. Yüksek hacme sahip ürünlerin talep tahmininde üstel düzeltme yöntemi başarılı sonuçlar verirken düşük hacme sahip, aralıklı talebin olduğu durumlarda üstel düzeltme yöntemi başarılı sonuçlar vermemektedir (Saatçioğlu, 2016).

Hareketli ortalamalar yöntemi

Basit ve yaygın olarak kullanılan yöntemlerden biri de hareketli ortalamalar yöntemidir. Geçmiş dönemdeki veriler incelenir ve verilerin zamanla ortaya koyduğu eğilim bulunur. Eğilim doğrusundan yararlanarak gelecek dönemdeki talep tahmini yapılır (Yavuz & Deveci, 2012). Hareketli ortalamalar yönteminde n kadar dönemin basit aritmetik ortalaması alınarak hesaplama yapılır. Bu yöntemle tahmin yapılırken 2.2’de belirtilen denklemle hesaplama yapılır (Saatçioğlu, 2016).

$$F_t = MA_n = \left(\frac{1}{n}\right) \sum_{i=1}^n A_{t-i} = \frac{A_{t-n} + \dots + A_{t-2} + A_{t-1}}{n} \quad (2.2)$$

F_t = t dönemi için tahmin

MA_n = n dönemi hareketli ortalaması

A_{t-1} = $t-1$ dönemi için gerçekleşen talep

n = hareketli ortalama kullanılan dönem sayısı

3. MAKİNE ÖĞRENMESİ

Bu bölümde yapay zekânın bir alt disiplini olan makine öğrenmesi kavramlarına, yapay sinir hücresi oluşum sürecine, yapay sinir ağlarının kurgulanmasına ve sınıflandırılmasına yer verilmiştir. Uygulama sürecinde kullanılan geri beslemeli sinir ağlarından olan LSTM modeli detaylı bir şekilde açıklanmıştır.

3.1. Yapay Zekâ

Zekanın özelliklerini sergileyen sistemleri anlamayı ve geliştirmeyi amaçlayan felsefe, matematik ve bilgisayar bilimli kökleri olan geniş bir bilimsel disiplindir. Makine öğrenmesi ise bu disiplinin bir alt disiplinidir.

3.2. Makine Öğrenmesi Kavramsal

Makine öğrenimi, bilgisayar programları (algoritmalar) verilerdeki örneklerden tahmin gücü, ilişkilendirme, öğrenme gibi konularda yapay zekânın alt disiplinidir. Makine öğrenimi, en basit haliyle istatistiksel modellerin bilgisayar kullanılarak verilere uygulanmasıdır. Makine öğrenimi, tipik olarak kullanım alanlarında geniş bir dizi istatistiksel teknik kullanmaktadır. Diğer taraftan derin öğrenme gibi daha yeni teknikler, temel alınan veriler hakkında daha az varsayıma sahip modellere dayanmaktadır. Makine öğrenmesinin bir alt dalıdır (Panch, Szolovits, & Atun, 2018).

3.2.1. Derin öğrenme

Derin öğrenme yöntemleri, bir makinenin büyük miktarlarda ham verilerle beslenmesine ve de ilişkilerin keşfedilmesine izin vermektedir. Bu nedenle daha karmaşık verilerin işlenmesinde kullanılabilir. Derin öğrenme yöntemleri, birden çok katmanlı sinir ağlarına dayanır. Derin öğrenme denetimli veya denetimsiz olabilir. Derin öğrenme yöntemleri, bilgisayar işlem gücünün artması ile makine öğrenimindeki son zamanlarda temel gelişmelerin alanlarından olmuştur (Panch, Szolovits, & Atun, 2018).

Öğretmenli (Supervised) öğrenme

Makinenin öğrenebilmesi için bir öğretmene ihtiyacı vardır. Öğretmen, her örnek olay için girdileri ve çıktıları makineye paket halinde tanıtır. Makineye girdileri

öğretmenin istediği çıktılara bağlamakla görevlidir. Bunun amacı girdiler ile çıktıların ilişkisinin tespitinin yapılmasıdır.

Destekleyici (Reinforcement) öğrenme

Bu stratejide de öğretmenli öğrenme stratejisinde olduğu gibi bir öğretmen vardır. Ancak farklı olarak öğretmen girdileri tanımlarken çıktıları makinenin üretmesini bekler. Öğretmen çıktıların doğruluğunu veya yanlışlığını gösteren sinyaller gönderir. Makine gelen sinyali dikkate alarak öğrenmeye devam eder.

Öğretmensiz (Unsupervised) öğrenme

Makinenin öğrenebilmesi için herhangi bir öğretmene ihtiyacı yoktur. Girdi değerleri makineye verilir. Örneklerin parametrelerini ilişkilendirme görevi makinenindir. Öğrenme tamamlandığında çıktıları anlamlandırma görevi kullanıcıya aittir. Bu sistem genellikle sınıflandırma amaçlı kullanılır.

3.3. Yapay Sinir Ağları Tanımı

Yapay sinir ağları insan beynine benzer şekilde öğrenme yolu ile yeni bilgiler türetebilme, oluşturabilme, keşfedebilme gibi yetenekleri herhangi bir yardım almadan otomatik olarak yapabilmek amacı ile geliştirilen bilgisayar sistemleridir.

İnsan beyninin fonksiyonel özelliklerinden bazılarını yapay sinir ağları da barındırır. Aşağıda bazıları ifade edilmiştir.

- Öğrenme
- İlişkilendirme
- Sınıflandırma
- Genelleme
- Özellik belirleme
- Optimizasyon

Yapay sinir ağları bu konularda başarılı bir şekilde uygulanmaktadır (Adıyaman, 2007).

3.4. Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları birden çok basit işlemci elemanın girdilerden çıktılar ürettiği bir kara kutu olarak tanımlanmaktadır. Bahsi geçen basit yapılu hücreler hiyerarşik yapıdır. Kara kutu matematiksel fonksiyona benzetilebilir. ANN'nin bu fonksiyonunda matematiksel olarak net bir ifadesi yoktur. Matematiksel fonksiyonlardan farklı olarak denklemlerle değil örneklerle çalışmaktadır.

Kara kutu olarak adlandırılan yapay sinir ağlarının işlevi bilgi toplama ve toplanan bilgileri işleyip gerekli bölüme göndermektir. Bununla ilgili çeşitli algoritmalar ve yaklaşımlar bulunmaktadır.

Yapay sinir ağları gerçekleşmiş olaylardan deneyim kazanarak öğrenmektedir. Bu nedenle matematiksel sistemlerdeki gibi bilgi toplama problemi yoktur, örneklerden yararlanır. Kullandığı örnekler sistemin öğrenmesi istenen durumları doğru bir şekilde temsil etmelidir.

Ağın performansını problemin temsil şeklinin yanında yapısı, ağın öğrenme sistemi ve kuralları etkiler. Ağın içerisindeki işlemci elemanları sürekli iletişim halindedir.

Yapay sinir ağlarını oluşturan katmanlar; girdi katmanı, ara katmanı ve çıktı katmanıdır.

Girdi Katmanı: En az bir girdi verisi içerir. Bu katmanda verilere bir işlem uygulanmaz.

Ara Katmanlar: Girdi katmanından gelen veriler belli başlı işlemlere tabii tutulur. Ara katmanın yapısı yapay sinir ağının yapısına bağlıdır, değişkenlik gösterebilir. Bir katman ya da birden çok katman içerebilir.

Çıktı Katmanı: En az bir çıktı içerir. Çıktıyı ağın içerdiği fonksiyon belirler. Burada çeşitli işlemler gerçekleştirilir ve çıktılar dış dünyaya aktarılır.

Geçmişten alınan veriler sisteme girdikten sonra işlemci elemanları ve bağlantı elemanları süreci çıkışa ulaştırmaktadır. Biyolojik sinir hücreleri basit bir yapay sinir hücresine göre oldukça karmaşık bir yapıdadır (Ballı, 2014).


Yapay sinir ağları hücrelerin bağlanma biçimlerine göre ileri beslemeli ve geri beslemeli olarak iki başlıkta incelenir (Slaughter, 2003).

3.4.1. Yapay sinir ağlarının temel bileşenleri

Biyolojik sinir hücresi

Biyolojik sinir sistemi, merkezi bir yapı (beyin) tarafından yönetilen üç katmanlı bir sistem olarak tanımlanır. Biyolojik sinir sistemi beynin kontrolünde bilgiyi alır, yorumlar ve karar verir.

Şekil 3.1’de blok diyagramı verilen biyolojik sinir sistemi kapalı çevrim blok diyagramı olarak çalışmaktadır.




Şekil 3.1. Biyolojik sinir sistemi blok diyagramı

Alıcı sinirleri görevi dış ortamdaki gelen veriyi beyne iletmek amacıyla elektriksel sinyallere dönüştürmektir. Tepki sinirleri merkezi yapı tarafından yorumlanan uyarıyı canlı organizmaya uygun tepkiye dönüştürmektir. Bahsi geçen işlemleri gerçekleştirirken sistemin yapı taşı sinir hücreleridir (nöron). Nöronların görevi bilgi akışını sağlamaktır.

Beynin çalışma sisteminde hayati öneme sahip olan nöronlardan insan beyinde milyarlarca olduğu tahmin edilmektedir.

Sinir hücresi; alıcı lifler (dendrit), sinyal iletici lifler (akson), hücre gövdesi (soma) ve sinapslardan olmak üzere dört birimden oluşmaktadır. Şekil 3.2’de bir sinir hücresinin yapısı gösterilmektedir.




Şekil 3.2. İnsan sinir hücresi yapısı

Dentritler, bilgiyi hücre gövdesine iletmekle görevlidir. Hücre çıktılarını diğer hücrelere aktarma görevi ise aksonlarıdır. Milyarlarca nöron bu sistemle çalışmaktadır. Akson - dentrit bağlantısı kurulan noktalara sinaps adı verilir ve sinapsa gelen bilgiler çoğunlukla elektriksel darbeler olarak tanımlanır. Elektriksel darbelerin belirli bir seviyeye ulaşmış olması hücrenin tepki verebilmesi için önem taşımaktadır. Bahsi geçen seviye eşik değeri olarak tanımlanır. Sinir hücresinin kendi elektrik sinyalleri somadan gelen bilgilerin bazı işlemlere tabi tutulması ile oluşur. Oluşan sinyaller akson vasıtasıyla dentritlere iletilir. Dentritler sinaps aracılığıyla sinyalleri diğer hücrelere iletir. Yapay sinir ağları bu sisteme örnek alınarak geliştirilmiştir (Öztemel, 2012).


Yapay sinir hücresi

Yapay sinir hücreleri biyolojik sinir hücreleri örnek alınarak geliştirilmiştir. Matematiksel modellere dayanır. Giriş verileri öncelikle sisteme öğretilen ağırlık değerleri ile çarpılır ve toplanır. Toplanan değer belli bir eşiği aşarsa hücre etki oluşturur. Yapay sinir hücrelerinde temel mantık bu şekildedir. Yapay sinir hücresi, girdi verilerini toplayan daha sonra eşik fonksiyonunu kullanarak bir değer üreten sistemdir.

Aktivasyon fonksiyonu olarak sigmoid fonksiyon kullanılmış bir yapay sinir hücresinin yapısı Şekil 3.3'te ve detaylı gösterimi Şekil 3.4'te gösterilmiştir.



Şekil 3.3. *Yapay sinir hücresinin basit yapısı*



Şekil 3.4. Yapay sinir hücresinin yapısı

Her bir giriş (x), ağırlık (w) ile çarpılarak toplanır ve sonucu oluşturmak için bir aktivasyon fonksiyonu ile işlem yapılarak eşitlik 3.1’de verildiği gibi hücre çıkışı (y) üretilir. Hücre çıkışı $y = f(\Sigma)$ şeklinde hesaplanır ve bu çıkış (y), seçilen transfer fonksiyonuna bağlıdır (Yazıcıoğlu, 2010).

$$y_i = f\left(\sum_{j=0}^n w_{i,j} x_j\right) \quad (3.1)$$

Yapay sinir hücresinin temel elemanları

İşlemci olarak adlandırılan yapay hücreler, yapay sinir ağlarının temel birimleridir. Bir yapay hücre biyolojik yapıdaki bir hücre ile kıyaslandığında daha basit bir yapıya sahip olmasına rağmen, genel olarak biyolojik hücrelerin bazı temel işlevlerini taklit etmektedirler. Bu işlevler 5 başlık altında toplanabilir (Yazıcıoğlu, 2010).

Girişler

Girişler ($x_1, x_2, x_3, \dots, x_n$) dış dünyadan veya başka bir sinir hücresinden gelen bilgilerin ara katmana gönderilmesi işlemini gerçekleştirirler. Bu gönderim sırasında herhangi bir bilgi işleme gerçekleşmez. Gelen bilgiler aynen sonraki katmana iletilirler (Yazıcıoğlu, 2010).

Ağırlıklar

Ağırlıklar ($w_1, w_2, w_3, \dots, w_n$), yapay sinir ağı tarafından alınan girişlerin sinir hücresi üzerindeki etkisini belirleyen katsayılardır. Bir sinir ağında her bir hücrenin her bir girişi için bir ağırlık vardır. Bir ağırlığın değerinin büyük olması, o girişin sinir

hücresine güçlü bağlanması ya da önemli olması, küçük olması zayıf bağlanması ya da önemli olmaması anlamına gelmektedir (Yazıcıoğlu, 2010).

Toplama işlevi

Toplama işlevi, sinir ağındaki bir hücrenin her bir giriş (x) ile o girişe ait ağırlık (w) değerlerinin çarpımlarının toplamının ifade edilmesidir (Yazıcıoğlu, 2010).

$$Toplam = \sum_i^n x_i w_i \quad (3.2)$$

Bununla beraber çoğu uygulamada eşik değeri olan bir θ değeri toplama dahil edilmektedir.

$$Toplam = \sum_i^n x_i w_i + \theta \quad (3.3)$$

θ eşik değeri girişlerden tamamen bağımsız bir değerdir ve bütün girişlerin sıfır olması durumunda dahi hücre çıkışının sıfır olma durumunu ortadan kaldırmaktadır.


Aktivasyon fonksiyonları

Aktivasyon fonksiyonları, toplama işlevi ile belirlenen toplam hücre giriş değerini işleyerek hücre çıkışını belirleyen fonksiyonlardır. Hücre modellerinde, hücrenin gerçekleştireceği işleve göre çeşitli türlerde aktivasyon fonksiyonları kullanılabilir. Bir ağıdaki bütün hücrelerin aktivasyon fonksiyonları aynı olabileceği gibi birbirinden farklı da olabilirler. Yaygın olarak kullanılan bazı aktivasyon fonksiyonları aşağıdaki gibi sıralanabilir (Yazıcıoğlu, 2010).

- Simetrik Eşik Aktivasyon Fonksiyonu:

McCulloch-Pitts modeli olarak bilinen eşik aktivasyon fonksiyonlu hücreler, mantıksal çıkış verir ve sınıflandırıcı ağlarda tercih edilirler. Perseptron olarak da bilinen eşik fonksiyonlu hücrelerin matematiksel modelleri denklem 3.4'de olduğu gibi tanımlanırlar. Şekil 3.5'de gösterilen tek kutuplu ve çift kutuplu olmak üzere iki çeşidi vardır.

$$y = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases} \quad y = \begin{cases} 1 & x \geq 0 \\ -1 & x < 0 \end{cases} \quad (3.4)$$




Şekil 3.5. Simetrik eşik aktivasyon fonksiyonları

- Lineer Aktivasyon Fonksiyonu:

Şekil 3.6'da belirtilen lineer aktivasyon fonksiyonunda toplayıcıdan gelen veriler bir α katsayısı ile çarpılır. $\alpha=1$ ise fonksiyon çıkışı girişine eşittir. Adaline olaraktan bilinen bu model, sıklıkla klasik işaret işleme ve regresyon analizlerinde kullanılır.

$$y = F(x) = \alpha x, \alpha = 1 \quad (3.5)$$




Şekil 3.6. Lineer aktivasyon fonksiyonu

- Sigmoid Aktivasyon Fonksiyonu:

Şekil 3.7'de grafiksel olarak gösterilen denklem 3.6'da formül olarak verilen aktivasyon fonksiyonu ANN'lerde en çok kullanılan, doğrusal ve doğrusal olmayan davranışlar arasında denge sağlayan sürekli artan bir fonksiyon olarak tanımlanır.

$$y = \frac{1}{1 + e^{-x}} \quad (3.6)$$




Şekil 3.7. Sigmoid aktivasyon fonksiyonu

- Hiperbolik Tanjant Aktivasyon Fonksiyonu:

Denklem 3.7’de formülize edilmiş olarak verilen hiperbolik tanjant aktivasyon fonksiyonunun türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olması nedeniyle doğrusal olmayan problemlerin çözümünde kullanılan bir aktivasyon fonksiyonudur. Şekil 3.8’de gösterilen bu aktivasyon fonksiyonunda giriş olarak $-\infty$ ile $+\infty$ arasında herhangi bir değer alır ve çıkış değeri -1 ile +1 arasındadır. Literatürde çift kutuplu fonksiyon olarak da adlandırılır.

$$y = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (3.7)$$



Şekil 3.8. Hiperbolik tanjant aktivasyon fonksiyonu

Çıkış işlevi

Çıkış $y = f(x)$, aktivasyon fonksiyonunun diğer sinir hücrelerine gönderilmesi veya elde edilmek istenilen işlem çıkışı ya da sonuç olarak tanımlanır. Ayrıca bir hücrenin çıkışı kendisine ve kendisinden sonra gelen bir veya daha fazla hücreye giriş olabilir (Yazıcıoğlu, 2010).

Epoch

Model eğitilirken verilerin tamamı aynı anda eğitime katılmaz. Eğitim setinde bölümler halinde eğitimde yer alırlar. İlk parça eğitimin ardından, modelin başarısı test edilir, başarıya göre geriye yayılım ağırlıkları güncellenir. Sonra yeni eğitim kümesi ile model tekrar eğitilir ve ağırlıklar tekrar güncellenir. Bu işlem her eğitim adımında tekrarlanarak model için en uygun ağırlık değerleri hesaplanmaya çalışılır. Bu eğitim adımlarının her birine “epoch” denilmektedir.

Öğrenme oranı


Derin öğrenmede parametrelerin güncellenmesi geriye yayılım işlemi ile yapılmaktadır. Geriye yayılım işleminde bu güncelleme için geriye doğru türev olarak farkın bulunması ve bulunan fark değerinin “learning rate” parametresiyle çarpılması, çıkan sonucun ağırlık değerlerinden çıkarılarak yeni ağırlık değerinin hesaplanmasıyla yapılmaktadır.

3.5. Yapay Sinir Ağlarının Mimarilerine Göre Sınıflandırması

Birden fazla yapay sinir hücresi (nöron) birleştiğinde ortaya yapay sinir ağı çıkar. Bir adet yapay sinir hücresi karmaşık problemlerin çözümünde kullanılamaz ancak yapay sinir ağları bu işlevi yerine getirebilir. Yapay sinir hücrelerinin birbirine bağlanma şekilleri ağ mimarisi olarak adlandırılır. Çok çeşitlendirilmeleriyle birlikte genellikle ileri beslemeli ve geri beslemeli olarak iki başlıkta incelenirler (Krenker, Bester, & Kos, 2011).

3.5.1. İleri beslemeli ağlar


İleri beslemeli ağlar adından da anlaşıldığı gibi ters bir akış olmadan veriyi ileri yönde işler. Girdi verisinde giriş katmanına sonra ara katmana en son da çıktı katmanına doğru ilerler. Her katmandaki yapay sinir hücreleri bir önceki katmana ait yapay sinir hücreleri tarafından beslenir. İleri beslemeli ağa örnek olarak MLP ve LVQ sayılabilir (Yavuz & Deveci, 2012). Şekil 3.9’da ileri beslemeli nöron ağı yapısı gösterilmiştir.



Şekil 3.9. İleri beslemeli ağ (Yavuz & Deveci, 2012)

3.5.2. Geri beslemeli ağlar


Yapay sinir ağlarında en az bir hücre kendinden sonraki hücre tarafından besleniyorsa bu ağlara “geri beslemeli ağlar” denir. RNN, LSTM, RBF, SOM, ART vb. ağlar bu sınıfa örnek verilebilir (Görsel 3.10). Bu çalışma kapsamında RNN ve LSTM yer verilmiştir. Bu ağlar bir sonraki kısımda detaylı olarak incelenmiştir.



Şekil 3.10. Geri beslemeli ağ (Yavuz & Deveci, 2012)

3.6. Tekrarlayan Sinir Ağları


RNN (Tekrarlayan Sinir Ağları), çıktı verilerinin sinir ağının ardışık, zaman serisi girdilerinin hesaplanması sonucuna bağlıdır. Tekrarlayan sinir ağları, ileri beslemeli yapay sinir ağlarından ayrılarak geçmişte kullandığı girdi verilerini modele alırken kendi hafızasını kullanır. RNN zaman serisi verilerini işler. Uygulama alanlarına el yazısı, konuşma ve sınıflandırma gerektiren faaliyetler girer. Şekil 3.11’de RNN açık bir şekilde gösterilmiştir. Eğitimi için yapay sinir ağlarında görmeye alışık olduğumuz geri beslemeli (Backpropagation) kullanılır. Bu sistemde RNN’nin büyük bir handikapı vardır. Tüm ağırlıklar gradyan tarafından ayarlanır. Gradyan yalnızca mevcut katmana bağlı değildir, bir önceki katmandan da etkilenir. Geri beslemeli sinir ağları birden çok zaman aralığında sürekli yenilenmesiyle sonuç küçülür. Bunun sonucunda “kaybolan gradyan” problemi doğar ya da gradyan birden büyük ise “patlayan gradyan” problemi oluşur. Çözüm için LSTM mimarileri geliştirilmiştir (Metin & Karasulu, 2019).



Şekil 3.11. Tekrarlayan sinir ağları

3.7. Uzun- Kısa Süreli Bellek Ağları

LSTM (Uzun Kısa Süreli Bellek Ağları) ilk olarak 1997 yılında Hochreiter & Schmidhuber tarafından tanımlanmıştır. Daha sonraları birçok kişi geliştirmek üzere çalışmıştır. LSTM, RNN mimarisi ailesindendir. RNN mimarisinden ayrılan özelliği ise işlemi üzerinden çok zaman geçmiş girdiyi hatırlayabilmesidir. Bunu sağlayan ise hafıza hücreleri isminde gizli birimleridir. Dört temel katmandan oluşur; unutma, girdi, güncelleme ve çıktı katmanlarıdır (Görsel 3.12). LSTM, girdi verisinin önemine göre kaydedilme veya kaydedilmeme kararını veren kapılar bulundurur (Hochreiter & Schmidhuber, 1997).



Şekil 3.12. Uzun kısa süreli bellek ağları

LSTM'nin yapısı

Uzun Kısa Süreli Bellek Ağları mimarisi tekrarlı sıralardan oluşan bloklar içerir. Öncelikli hedef x_t ve h_{t-1} verilerinden yararlanılarak silinecek veriyi seçmektir. Denklem 3.8 vasıtasıyla bu işlemler unut katmanında tamamlanır.

$$f_t = \sigma(W_{f,x}x_t + W_{f,h}h_{t-1} + b_f) \quad (3.8)$$

İkinci katman girdi katmanıdır. Bu adımda yeni bilgiler içeren girdi katmanı çalışır. İlk olarak (i_t) ve denklem 3.9b yardımıyla sigmoid fonksiyonu da kullanılarak bilgiler güncellenir. Bu aşamada son olarak $\tanh$ fonksiyonu yeni bilgi için aday bilgileri belirler.

$$i_t = \sigma(w_{i,x}x_t + w_{i,h}h_{t-1} + b_i) \quad (3.9a)$$

$$C_t = \tanh(w_{c,x}x_t + w_{c,h}h_{t-1} + b_c) \quad (3.9b)$$

Yeni bilgiler denklem 3.10 ile oluşur.

$$C_t = C_{t-1}f_t + i_tC_t \quad (3.10)$$

Çıktı katmanında denklem 3.11a ve 3.11b kullanılarak çıkış verileri bulunur.

$$o_t = \sigma(W_{o,x}x_t + W_{o,h}h_{t-1} + b_o) \quad (3.11a)$$

$$h_t = o_t \tanh(C_t) \quad (3.11b)$$

Bu süreç tekrarlayarak sürer. Ağırlık (W) ve bias (b) parametreleri LSTM çıkış verileri ile eğitim verileri arasında oluşması muhtemel farkı minimize etmek için model kullanılarak öğrenilir (Kara, 2019).

4. ZAMAN SERİLERİ

Zaman serileri sayısal olarak ifade edilebilecek olayları, geçmiş bir zaman diliminde belirli bir aralığı – dönemi kapsayan veri dizileridir. Bu kısımda zaman serilerinin en temel yapısına ve zaman serileri için kullanılan doğrusal modellere genel bir bakış açısı ile yaklaşılmıştır. Uygulamada kullanılan ARIMA ve SARIMA yöntemlerinin anlatımlarına yer verilmiştir.

Zaman serisi modelleri, verilerin eğilim gösterip göstermediğini, zamansal değişim şeklini, nasıl davranış sergilediğini analiz eden ve matematiksel ifadelerle gösteren yöntemlerdir. Zaman serileri üzerinde tahmin üretebilmemiz için zaman serisinin nasıl bir davranış sergilediğini bilmemiz gerekmektedir.

Zaman serilerinin nasıl davrandığını bilmemiz tahmin sürecinde, tahmin yaparken seçeceğimiz yöntemi birebir etkileyecektir.

4.1. Zaman Serileri Yapısı

Zaman serileri yapısına baktığımızda, zaman serisi içinde bulunan veriler (gözlemler) arasındaki örüntüler incelenmelidir. Zaman serisi incelenirken seriyi oluşturan veriler arası bağımlılık araştırılmalı ve ortaya çıkarılmalıdır. Literatürde zaman serilerini oluşturan dört temel bileşenden söz edilmektedir.

- Trend (Eğilim)
- Dönemsel hareketler
- Mevsimsel hareketler
- Rasgele olaylar

Zaman serisi (y_t) veri seti içerisinde trend (T), dönemsel hareketler (D), mevsimsel hareketler (S), rasgele olaylar (R) hepsini barındırabileceği gibi farklı kombinasyonlarla bazı durumları barındırmayabilir. Literatürde zaman serisi dört durumu bir arada içeriyorsa toplamsal model denklem 4.1'deki şekilde ifade edilmiştir.

$$y_t = (T + D + S + R) \quad (4.1)$$

Çalışmanın içerisinde yer alan zaman serileri ‘Zaman serilerinin içinde doğrusal ve doğrusal olmayan örüntüler barındırmaktadır’ ifadesi üzerine kurgulanmıştır. Zhang (2003) da yayınladığı zaman serilerinde tahmin üretimi için hibrit modelinde zaman

serisinin doğrusal, doğrusal olmayan olaylardan meydana geldiğini ve bu olaylar arasında bir bağ olduğunu ifade etmiştir.

$$y_t = (L_t + N_t) \quad (4.2)$$

Eşitlik 4.2’de gösterilen doğrusal bileşen L_t , doğrusal olmayan bileşen ise N_t ile ifade edilmektedir. Bu çalışma hibrit model bölümünde detaylı olarak anlatılmıştır.

4.2. Doğrusal Zaman Serisi Modelleri

Doğrusal zaman serileri modellerinde otoregresif (AR), hareketli ortalama (MA), otoregresif hareketli ortalama modelleri (ARMA), bütünleşik otoregresif hareketli ortalama modelleri (ARIMA) ve mevsimsel bütünleşik otoregresif hareketli ortalama modelleri (SARIMA) söz edilebiliriz. Bu kısımda kısaca bazı modeller ve özellikleri incelenmiştir.

ARIMA tek değişkenli kısa dönem tahminlerinde başarılı bir şekilde kullanılmakta ve gözlenen verilerin kesikli ve durağan bir veri seti olması gerekmektedir. Bu özelliklerine göre üç ana grupta ayrıştırabiliriz.

1. Durağan ARMA Modelleri
 - a. AR (Oto regresif Sürec Modelleri)
 - b. MA (Hareketli Ortalama Modelleri)
 - c. ARMA (Oto regresif Hareketli Ortalama Modelleri)
2. Durağan Olmayan ARIMA Modelleri
3. SARIMA (Mevsimsel Modeller)

Doğrusal zaman serilerinin analiz modellerine geçmeden bu modellerde önemli bir kavram olan durağanlık kavramını incelememiz gerekir.

ARIMA yöntemine göre değişken verinin gelecekteki değerinin, geçmişteki birkaç değeri ile rastsal hataların doğrusal fonksiyonu olduğu varsayılmaktadır. Eşitlik 4.3’de durağanlaştırmak için d kez farkı alınan serinin $ARIMA(p,d,q)$ modeline uygunluğu açıkça görülmektedir.

$$\begin{aligned} (1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d Y_t \\ = (1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q) e_t \end{aligned} \quad (4.3)$$

Y_t : t zamanında gerçek değer

e_t : Rastsal hata

Φ_i ($i= 1,2,\dots,p$) : AR parametreleri

θ_j ($j= 0,1,2,\dots,q$) : MA parametreleri

p ve $q \in Z$: Model derecesi

$(1-B)^d$: d 'nci dereceden fark işlemi

e_t ortalaması 0, varyans sabitken bağımsız ve aynı dağılmış varsayılır. Yukarıdaki eşitlikte $q=0$ ise model p dereceli AR modelidir, eğer $p=0$ ise model q dereceli MA modelidir. ARIMA(p,d,q), durağan olmayan serilerle işlem yapılırken kullanılır. AR(p), MA(q) ve ARMA(p,q) kombinasyonları, ARIMA(p,d,q) modelinden farklı olarak durağan seriler için kullanılır (Ateşoğlu, 2015).

4.2.1. ARIMA model belirleme süreci

Öncelikle bazı varsayımlar yapılmaktadır. Daha sonra ARIMA modelinin seçilmesi gerekmektedir. Bu varsayımlar aşağıda belirtilmiştir.

1. Durağan veriler olmalı
2. Veriler normal dağılım göstermeli
3. Aykırı durumda veri olmamalı
4. Veri setinde eksik veri olmamalı

Model oluşturulurken ilk önce modelin tanımlanması gerekir. Zaman serisini durağanlaştırmak için veri dönüşümü gereklidir. Zaman serisinin ortalaması ve oto korelasyonu istatistiksel olarak sabitlenerek zaman serisi süreç içinde durağan olarak tanımlanabilmelidir. Zaman serisinde varyans değişken olduğunda, sezon veya trendi görülüyorsa; ARIMA modeli uygulanmadan önce fark işlemleri yapılarak varyans değişkeni ve trend sabit hale getirilmektedir (Ateşoğlu, 2015).

Eğer seriler durağan değil ise, d 'inci dereceden fark alma işlemi uygulanarak seri durağan hale getirilir. Fark alma derecesini gösteren d ; durağan serilerde 0, birinci dereceden fark alma işlemiyle durağan hale gelen serilerde 1, ikinci derece fark alma işlemi ile durağanlık sağlanan serilerde ise 2 değerini alır. Uygulamada genellikle d 'nin değeri 1 ya da 3 olarak alınmaktadır. Ancak, serilerin durağan olması halinde seriye herhangi bir fark alma işleminin uygulanmasına gerek yoktur. En uygun ARIMA modelini tanımlamak için IACF (ters oto korelasyon), PACF (kısmi oto korelasyon) ve ACF (oto korelasyon) fonksiyonlarının en uygun p, d, q parametreleri dikkatle kontrol edilmelidir. ARMA modelinin derecesinin belirlenmesi ise, AR ve MA kısımları için ayrı ayrı yapılmaktadır. AR kısmının derecesi istatistiksel olarak sıfırdan farklı kısmi oto korelasyon sayısına, MA kısmının ise istatistiksel olarak sıfırdan farklı oto korelasyon sayısına bakılarak belirlenir. ARIMA modelinde p, d, q değerleri belirlendikten sonra geçici parametre değerleri tahmin edilir. AR (p), MA (q) ve ARMA (p, q) modellerinde en uygun model tipi tablo 4.1'deki kriterlere göre seçilmektedir (Temür, 2019).

Tablo 4.1. Durağan zaman verilerinde ACF ve PACF'nin teorik davranışları

Model	ACF (Otokorelasyon Fonksiyonu)	PACF (Kısmi Otokorelasyon Fonksiyonu)
AR (p)	Üstel şekilde ve/veya sinüs dalgaları şeklinde azalma gerçekleşir.	p kadar gecikmeden sonra istatistiksel olarak anlamlı değildir.
MA (q)	q gecikmesinden sonra sıfır noktasını keser.	Üstel şekilde ve/veya sinüs dalgaları şeklinde azalır.
ARMA	$p-q$ kadar gecikmenin ardından üstel şekilde ve/veya sinüs dalgaları şeklinde azalarak sıfır noktasını keser.	$p-q$ kadar gecikmeden sonra üstel ve/veya sinüs dalgaları şeklinde azalır.

Potansiyel modeli bulmak için teorik ve deneysel bilgilerden bir arada yararlanılarak farklı modeller seçilmesine izin verilmelidir. Birçok model arasında seçim için MDL (Orta Tanım Genişliği) ve AIC (Akaike Bigi Kriteri) yöntemlerini uygulamak ve kriterlerin geçerliliğini belirlemek gerekmektedir (Zhang G. , 2003).

İkinci adımda bilinmeyen parametre tahmini yapılır. Hata ölçüsü parametreleri EKK yöntemi ile tahmin üretmekte ve bu aşamada eniyileme süreci kullanımı doğrusal olmayan modelin gerçekleşmesine izin vermektedir. Üçüncü adımda artıklar kontrol edilir. Model oluşturma aşamasında modelin yeterli olup olmadığı kontrol edilmektedir. Sonuç grafiği oluşurken, tarihsel ve istatistiksel verilerden artıkların grafiği için kurulan kısa vadeli model uyumluluğu inceleme için kullanılabilir. Modelin yetersiz olması

durumunda yeni kısa vadeli model tanımlanmalı ve inceleme yapılmalıdır. Sonraki süreçte oluşan parametre için yeni tahmin ve model doğruluğu adımına geçilmelidir. Modelin yeterliliği sağlanana kadar üç aşama yeniden gerçekleştirilmektedir. En sonunda seçilen model ile gelecek dönemler için tahminler yapılmaktadır (Ateşoğlu, 2015).

4.2.2. Durağan olmayan ARIMA modelleri

Süreçlerin ortalaması, varyans ve kovaryans gibi istatistiksel özelliklerin zamana bağlı olarak değişmemesi durumunda, yani seriler durağan olduklarında $AR(p)$, $MA(q)$ ve $ARMA(p,q)$ modellerinden biri kullanılabilir. Gerçek hayatta zaman serilerinin birçoğu zaman boyunca değişen belirli bir skolaistik sürecin özelliklerini taşıdığından durağan olmazlar. Durağan olmayan zaman serilerini durağanlaştırmak için serinin bir veya daha fazla farkını alarak bir dönüştürme işlemi uygulanabilir. Farkı alınarak durağanlaştırılmış zaman serileri entegre süreç olarak bilinirler (Kaya, 2015).

Talep tahminini kullanışlı ve pratik hale getiren ARIMA modeli oluşturulurken durağanlık şarttır. Verilen zaman serisinin durağan olmaması halinde ise, durağan hale dönüştürme için uygun derecede fark (d) alma işlemi uygulanır ve durağanlığı tekrar sınanır. Durağan bir seri elde edene kadar bu işleme devam edilir. (d) pozitif bir tamsayıdır ve fark alma derecesinden sorumludur. Fark alma işlemi (d) kez gerçekleştirilirse, ARIMA modelinin entegrasyon parametresi (d) olarak ayarlanır. Daha sonra elde edilen durağan veri üzerinde işlem gerçekleştirilir. Bu işlem ile AR (otoregresif) ve MA (hareketli ortalama) işlemlerinin parametreleri sırasıyla (p) ve (q) belirlenir. Bir ARIMA modeli, $ARIMA(p, d, q)$ olarak tanımlanmıştır.

p : Oto-regresif modelin derecesi (AR)

d : Fark alma derecesi

q : Hareketli ortalama modelinin derecesi (MA)

∇ : Fark alma operatörü

w_t : Farkı alınmış seriyi ifade etmektedir.

$$e_t = \phi_1 w_{t-1} + \phi_2 w_{t-2} + \dots + \phi_p w_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (4.4)$$

Burada, t zamanı için x_t doğrusallaştırılmış gerçek veriyi, a_t hareketli ortalamaadaki hatayı ifade etmektedir. Denklem 4.4’de tahmin edilecek gerçek veri x_t ile gözlemlenen (p) tane farkı alınmış veri $(w_{t-1}, w_{t-2}, \dots, w_{t-p})$, ve (q) tane hata veri $(a_t, a_{t-1}, \dots, a_{t-q})$ arasında doğrusal bir ilişki kurulmuştur.

Mevsimsel dalgalanma göstermeyen serilerin geleceğe yönelik tahmininde kullanılmakta olan genel ARIMA (p,d,q) modelinde hesaplanması gerekli parametre sayısı ARMA (p,q) ’daki kadardır (Newbold, 1983).

4.2.3. Mevsimsel modeller

Aylık ya da üç aylık gibi belli zaman aralıklarına ilişkin gözlem değerlerinin oluşturduğu zaman serilerinin birbirini takip eden yılların aynı dönem aralıklarında maksimuma veya minimuma ulaşma eğilimi mevsim dalgalanmalarının göstergesidir. Sosyal ve doğal etkenler sonucunda meydana gelen ve her yıl düzenli bir şekilde tekrarlanan dalgalanmaları içeren seriler “mevsimsel zaman serileri” olarak adlandırılır.

SARIMA $(p,d,q) (s,P,D,Q)$ modellerinde p ve q modelin standart otoregresif ve standart hareketli ortalama derecelerini göstermektedir. P ve Q ise modelin mevsimsel otoregresif ve mevsimsel hareketli ortalama derecelerini temsil etmektedir. d ve D serinin durağanlığının sağlanabilmesi için sırasıyla kaçınıcı dereceden standart ve mevsimsel farkların alındığını ifade etmektedir. s mevsimsel farkın periyodik aralığını göstermektedir (Tortum, Gözcü, & Çodur, 2014). Mevsimsel dalgalanmalarda aylık gözlem değerleri $s=12$, 6 aylık periyoda sahip mevsimsel dalgalanmalarda ise $s=2$ ve üç aylık aralıklarla gözlemlenen dalgalanmalar $s=4$ ’tür.

Mevsimsellik, zaman serilerinde durağanlığı bozan unsurlardan birisidir. Bu serilerde durağanlığın sağlanması için serinin mevsim etkisinden arındırılması gereklidir. Bu amaçla gözlem değerlerinin s ’inci dereceden farkının alınması gerekliliğinden dolayı mevsimsel serilerin modellenmesinde s ’nin bilinmesi önem arz etmektedir (Kendel, 1973).

Yapılacak mevsimsel modelin hem mevsimlerin etkisiyle oluşan değişimleri hem de veri düzeyindeki değişimleri yansıtabilmesi gereklidir. Çünkü bir zaman serisi hem mevsimsel dalgalanmalar içerebilir hem de bir trende sahip olabilir. Bu özellikteki bir

zaman serisinin gözlem değerleri arasında iki türlü ilişki vardır; birbirini izleyen gözlem değerleri arasındaki ilişki ve mevsimsel ilişki SARIMAX olarak adlandırılmaktadır

SARIMA dan farklı olarak SARIMAX verilerin içinde sezonsal ya da farklı bir ilişki olabileceği gözlemlenmesi durumlarında kullanılır. Doğru tahminler üretebilmek için zaman serilerini içeren veri kümelerinde trendler ya da döngüler olabilir. ARIMA modeli mevsimsel eğilimlere izin verecek şekilde genişletilebilir ve SARIMA olarak bilinir. SARIMA modeli hem ARIMA'da yer alan mevsimsel olmayan faktörleri hem de mevsimsel faktörleri içermektedir. SARIMA modelinin durağan olması için (sabit ortalama ya da varyans) tahminlemeden önce mevsimsellik farkı uygulanmalıdır. Eksojen değişkenler tahmin performansını artırmak için bir SARIMA modeline entegre edildiğinde, eksojen değişkenlerle birlikte olan model SARIMAX olarak bilinir. SARIMAX modellerinin tipik olarak SARIMA'dan daha iyi performans gösterdiği görülmüştür. Veri setinin mevsimsel değişkenliğe sahip olması ve birden fazla dış faktöre bağlı olarak değişmesi nedeniyle, veri setini tahmin için SARIMAX da kullanılmaktadır. SARIMAX modelleri kısa dönemli tahminlerde tercih edilebilir (Hugh, Coleman, & Kerr, 2019).

5. HİBRİT

Bu çalışma içerisinde hibrit kavramı birden çok yöntemi bir arada kullanan ya da barındıran bir yaklaşım olarak ele alınmıştır. Bu çalışmada 2003 ile 2019 yılları arasında yapılmış hibrit model çalışmaları incelenmiştir. Son dönemlerde hibrit modellere yönelim artmıştır. Hibrit modellere olan yönelimin temelinde tek yöntemle çözülen problemlerin eksik kalan yönleri başka bir yöntemle tamamlanabilmektedir.

5.1. Hibrit Kavramı

Hibrit modeller içlerinde birden fazla yöntemde barındırılabilirdikleri için başka yöntemlerin dezavantajlarını ortadan kaldırabilmektedirler. Hibrit model yaklaşımlarında doğrusal ve doğrusal olmayan modeller bir arada kullanılabilir. Bu tür hibrit modeller, zaman serileri tahmin üretme amaçlı uygulamalarda literatürde iyi tahminler üretme konusunda başarılı olmuştur.

Zaman serilerinin doğrusal ve doğrusal olmayan olarak iki kısımdan oluştuğunu daha önceki bölümümüzde bahsedilmişti. Zaman serisinin bu yapısı denklem 5.1'deki gibi ifade edilir.

$$x_t = L_t + N_t + e_t \quad (5.1)$$

L_t , t zamanında verinin doğrusallığını temsil ederken, N_t doğrusal olmama anlamına gelir. e_t , hata terimidir.

Farklı hibrit modellerin gelişiminde veri setlerinin az bilgidan oluşması ve birbirinden farklı bağımsız değişken içermesi, bağımsız değişkenlerin tatmin edici sonuçlar vermemesi, tek modelin yetersiz olması hibrit modellerin doğuşuna ve yaygınlaşmasına sebep olmuştur. Geçtiğimiz otuz yıl boyunca zaman serisi tahmin modellerinde çalışmalar yapılmış ve ARIMA modeli popüler doğrusal modellerden birisi olmuştur. Zaman serilerinden ARIMA modelleri, doğrusal ilişkinin modellenmesinde iyi iken, doğrusal olmayan ilişkilerin modellenmesinde yetersiz kalmaktadırlar.

ANN (Yapay Sinir Ağları), çıkış ve giriş değişkenler arası bağlar bilinmeksizin doğrusallığı olmayan modellerde veriler arası ilişki kurma fırsatı sunmaktadır. ANN doğrusal ve doğrusal olmayan veriler arası bağlarla model üretme yeteneğine sahiptir fakat her veri yapısının özelliklerinin tamamen bilinmemesinden dolayı aynı düzeyde etkin sonuçlar sağlayamazlar (Temür, 2019).

Zaman serilerinde tahmin doğruluğunu arttırmak için doğrusal ve doğrusal olmayan modellerin birleştirmesi ile zaman serilerinde farklı hibrit modeller oluşturmak mümkün olmaktadır. Hibrit ya da çok modelli yaklaşımda temel amaç, yeni oluşan modelin her çıktısının veri setindeki farklı sonuçları daha iyi keşfeden benzersiz yetenekler bulmaktır. Hibrit modellerin birbirine uyumlu çalışması için kullanılan modellerin hatalarını ortadan kaldırmak adına deneysel ve teorik bulguları birbirinden farklı modellerin hata riskini azaltarak elde edilecek sonuçların amaca uygun bir şekilde kurgulanması ya da parametrelerde değişiklikler olması gerekmektedir (Ateşoğlu, 2015).

Hibrit modellerin vermiş olduğu sonuçların ve modellerin tek başına kullanılmaları ile elde edilen sonuçlar karşılaştırıldığında alakasız ya da benzersiz olsa da genel kabul ya da hata payının azaltılabildiği gözlemlenmiştir. Hibrit modellerle üretilen tahmin başarılı ise tek başına üretilen tahminlerden daha başarılı bir model türü olarak kabul etmek mümkündür.

5.2. Hibrit Modeller

Zhang'ın hibrit modeli

Zhang 2003 yılında, zaman serileri tahmini üretmek için hibrit bir model fikrini ANN ve ARIMA modellerini birleştirerek öne sürmüştür. Öne sürülen hibrit yaklaşıma göre, seçilen zaman serisinin doğrusal ve de doğrusal olmayan iki kısmın bileşeninin matematiksel olarak toplamı olduğunu varsayımı yapılmaktadır. Varsayımı 5.2'de matematiksel olarak tanımlamıştır.

$$y_t = L_t + N_t \quad (5.2)$$

Eşitlikte gösterilen doğrusal bileşen L_t , doğrusal olmayan bileşen ise N_t ile ifade edilmektedir. Bu bileşenler veriden tahmin edilmektedir. Modelin ilk aşamasında veri setinin doğrusal kısmının modellenmesi için ARIMA modeli uygulanır. Doğrusal modelin çıktıları veri setinin doğrusallığını ilgilendirir ve modelin eşitliği 5.3'de gösterilmiştir.

$$e_t = Y_t - \hat{L}_t \quad (5.3)$$

e_t t zamanı için doğrusal modelin (ARIMA) artığını temsil ederken, $\hat{L}_t$ t zamanında ARIMA modeli ile bulunan tahmin değerinin artığını, Y_t t zamanına ait gerçek değerini gösterir. Artık çıktıları, bizim için doğrusal modelin yeterliliğinin belirlemesi için

gereklidir. Doğrusal modelin yeterli olabilmesi için artıklarda hala doğrusal ilişki yapıları varsa, doğrusal model yeterli değildir. Doğrusal olmayan ilişkiyi bulmak için ise, artıklar ANN tarafından modellenenebilir.

$$\hat{e}_t = f(e_{t-1}, e_{t-2}, \dots, e_{t-n}) + \epsilon_t \quad (5.4)$$

Denklem 5.4’de f ANN’deki dönüştürme işlevidir ve ϵ_t rastgele hatadır.

ANN’den gelen tahmin ve ilk modelden gelen tahmin, $\hat{Y}$ serisinin tahminini elde etmek t için birleştirilir. Birleştirilmiş tahmin 5.5’deki eşitlikte gösterilmiştir.

$$\hat{Y}_t = \hat{L}_t + \hat{N}_t \quad (5.5)$$

$\hat{N}_t$ doğrusal olmayan bileşen için denklem 5.4’deki eşitlikten tahmin edilen t zamanı hata değeri ve Zhang’in hibrit modeli, bir sonraki adımda ileri ve çok basamaklı ileri tahminlerde kullanılmaktadır (Zhang G. , 2003).

Bu model, kullanıldığı makalede Wolf’un güneş lekeleri, Kanada’da vahşi kedi sayıları ve İngiliz sterlini - ABD doları döviz kuru verileri üzerinedir (Babu & Reddy, 2014).

Khashei, Bijari’nin hibrit modeli

Bijari ve Khashei tarafından 2010 yılında ileri beslemeli yapay sinir ağlarına dayanan hibrit bir model yaklaşımı önerilmiştir. Önerilen model yaklaşımı, zaman serisine ilişkin verilerin ya da veri setlerinin doğrusal ve doğrusal olmayan kısımlarının oluşturduğu ve bu kısımların toplamının bir veri setinin tamamını oluşturduğu varsayımı yapılmaktadır. Bijari ve Khashei tarafından 2010 yılında ileri sürülen yöntemin birinci adımında ARIMA modeli veri setine doğrusal kısımda uygulanır ve tahmin edilen çıktılar veri olarak kayıt altına alınır. Daha sonraki adımda ARIMA modelinin geçmiş artık çıktı dizisinin değerleri ile geçmişteki orijinal veri değerlerinin tamamı ANN’ye girdi verisi olarak verilecektir. İşlem sonucunda çıktılar, hibrit modelin tahmini için oluşmuş olan verilerin değerini göstermektedir.

Bu model, kullanıldığı makalede Wolf’un güneş lekeleri, Kanada’da vahşi kedi sayıları ve İngiliz sterlini - ABD doları döviz kuru verileri üzerinedir (Khashei & Bijari, 2010).

Khashei, Bijari'nin ikinci hibrit modeli

Bijari ve Khashei tarafından 2011 yılında aynı veri setleri için ileri beslemeli yapay sinir ağlarında kullanılarak ikinci bir hibrit model önerilmiştir. Yeni önerilen modelde, seçilen bir zaman serisine ait verilerin doğrusal ve doğrusal olmayan kısımlarının oluşturduğu ve bu kısımların toplamının bir veri setinin tamamını oluşturduğu varsayımı yapılmaktadır. Modelin veri setine ilk olarak ARIMA modeli uygulanır ve de tahmini veriler elde edilir. Sonraki adımda, orijinal veri değerleri ile geçmiş veriler, mevcut tahmin değerlerinin ARIMA geçmiş hata dizisi ile ANN veri girişi olarak verilir. Çıktılar sonuç tahmin değerlerini göstermektedir.

Bu model, kullanıldığı makalede Wolf'un güneş lekeleri, Kanada'da vahşi kedi sayıları ve İngiliz sterlini - ABD doları döviz kuru verileri üzerinedir (Khashei & Bijari, 2011).

Khashei, Bijari ve Ardali'nin hibrit modeli

2012 yılında Khashei, Bijari ve Ardali aynı veri seti için ARIMA modeli ile sınıflandırıcı olasılık sinir ağlarını (PNN) birleştirerek yeni bir hibrit model yaklaşımı ortaya çıkarmışlardır. Hibrit modelin üstlenmiş olduğu misyon, sınıf ayrıştırıcı model olarak PNN avantajlarından yararlanılması ve ARIMA modellerinin artıklarının mevcut eğiliminin belirlenmesidir.

Bu model, kullanıldığı makalede Wolf'un güneş lekeleri, Kanada'da vahşi kedi sayıları ve İngiliz sterlini - ABD doları döviz kuru verileri üzerinedir (Khashei, Bijari, & Ardali, 2012).

5.3. Çalışmada Kullanılan Hibrit Model Yaklaşımı

Bu çalışmada hibrit bir model olarak ARIMA ve LSTM'den oluşmakta olan bir hibrit modele yer verilmiştir. ARIMA doğrusal problemlerde iyi performans gösterdiği için tek başına zaman serisinde kullanılırsa yalnızca doğrusal olan kısmı için iyi tahminler üretmesi muhtemeldir. Bu nedenden kaynaklı olarak hibrit modelde ARIMA zaman serisi doğrusal kısmı çözerken, LSTM doğrusal olmayan kısmının çözümünde rol almaktadır. Hibrit modelde LSTM kullanılmasının avantajı, içerisinde barındırdığı kısa dönemli

hafızası nedeniyle doğrusal olmayan zaman serileri ile ilişki kurmasının diğer yapay sinir ağı modellerine kıyasen daha iyi sonuçlar elde etmektedir (Choi, 2018).

Veri seti içinde zaman bileşenlerinden oluşuyorsa, bu veri seti doğrusal olmayan ve doğrusal verilerden oluşan bir zaman serisi olarak adlandırılabilir. İyi düşünülmüş bir hibrit model geliştirmek için zaman serilerini iyi algılamak gerekir ve bu fonksiyonlar arasındaki bağları düzgünce analiz etmek gerekir. Zaman serisinde doğrusal ve doğrusal olmayan verilerden oluşmuş olması aralarındaki bağları ortaya çıkarmanın zor olduğu bir durum oluşturuyor olduğunu unutmamak gerekir.

Oluşturulacak modelin esnek bağları içermesi, gerçek veriye yakın bir bağ kurması anlamına gelmektedir. Oluşan hibrit modelin adaptasyonunda zaman serisi için iyi bir analize ve de sahip olmuş olduğu doğrusal ve doğrusal olmayan verileri adapte edilebilir olmalıdır.

Hibrit modelin seçim sürecinde, Choi (2018) tarafından yapılan hisse senetlerinin tahmini için geliştirmiş olduğu hibrit yaklaşımdan yararlanılmaktadır. Bu çalışmada kullanılan LSTM-ARIMA hibrit modeli denklem 5.6'da gösterilmiştir.

$$y_t = L_t + N_t \quad (5.6)$$

L_t zaman serisinin doğrusal bileşenini ARIMA gösterirken, N_t ise doğrusal olmayan bileşeni LSTM'de göstermektedir. Hibrit modelde sırasıyla ARIMA tahminleri ve LSTM tahminleri üretilmektedir. Hibrit modeldeki ağırlıklara karar verirken formül 5.7a, formül 5.7b, formül 5.7c, formül 5.7d'den yararlanılmaktadır.

$$lstm_{hata} = lstm_{ortalama_{hata}} \quad (5.7a)$$

$$arima_{hata} = arima_{ortalama_{hata}} \quad (5.7b)$$


$$lstm_{ağırlık} = lstm_{hata} / (lstm_{hata} + arima_{hata}) \quad (5.7c)$$

$$arima_{ağırlık} = 1 - lstm_{ağırlık} \quad (5.7d)$$

Hibrit modele ait tahmin formülü aşağıdadır.

$$\begin{aligned} hibrit_{tahmin}[i] \\ = lstm_{ağırlık}[i]lstm_{tahmin}[i] \\ + arima_{ağırlık}[i]arima_{tahmin}[i] \end{aligned} \quad (5.8)$$

Şekil 5.1'de ARIMA - LSTM oluşan hibrit modelin diyagramı verilmiştir.



Şekil 5.1. Hibrit model diyagramı

6. KARAR DESTEK SİSTEMLERİ

DSS (Karar Destek Sistemleri) karar vericinin karar verme sürecini destekleme amacı ile geliştirilmiş yazılımlardır. Kararların kalitesini geliştirir, karar verme sürecinde kararı destekleyici bilgiler sunmaktadır.

Karar destek sistemleri bilgi teknolojilerinin bilişim sistemlerinin alt grubudur. Karar destek sistemleri bilgi teknolojilerini, insan zekasını ve yazılımı bir arada kullanarak karmaşık problemleri çözebilmeyi hedefler.

DSS'nin işlevleri karar vermeyi kolaylaştıracak veriye ulaşmayı, sadeleştirmeyi ve analiz etmeyi sağlamaktır, veri odaklı ya da model odaklı olabilirler. DSS sisteminin başarılı olabilmesi için inşa etmeye çalışılan sistem tanımlamalıdır. Daha açık bir ifadeyle, iş hedefleri ile işin ihtiyaçlarının doğrultusunda yapılandırılmalıdır.

6.1. Karar Destek Sistemini Oluşturan Bileşenler

DSS temelde üç bileşeni bir araya gelmesi ile oluşan sistemlerdir. DSS kendi veri, model ve kullanıcı arabirimleri olmak üzere 3 temel bileşenin bir araya gelmesi ile ortaya çıkar. Bu üç temel bileşen şu şekilde ifade edilebilir (Turban, 1988).

1. Veri yönetim sistemleri
2. Model yönetim sistemleri
3. Arayüz yönetim sistemleri

Veri yönetim sistemleri: DSS'nin alt sistemidir. Verilerin depolandığı ve saklandığı yerdir. Veri tabanı olarak da adlandırılabilir. Veri tabanları model ve arayüzler için kaynak oluşturmaktadır. Bu veri tabanlarının birleşmesi ile veri ambarları ortaya çıkar.

Model yönetim sistemleri: DSS'nin alt sistemidir. Karar verme sürecinde gerekli olabilecek sonuçların üretimi için matematiksel yöntemler barındırır. Model yönetim sistemleri içerisinde finansal modeller, istatistiksel modeller, tahminsel modeller, analitik çözümler vb. modelleri barındırabilmektedir. Bu modeller veri ambarlarındaki verileri anlamlandırmak için kullanılmaktadır. Kullanıcının ihtiyacı olabilecek bütün sonuçları burada tasarlanmaktadır.

Arayüz yönetim sistemleri: DSS'nin üst sistemidir. Kullanıcının DSS sistemini yönetmesi için tasarlanmış arayüzler bütünüdür. Arayüzler kullanıcının model ve veri yönetim sistemlerini görmeden sonuca ulaşmasını sağlar. Burada kullanıcı veri yönetim sistemlerine ve model yönetim sistemlerine komut gönderme vasıtası ile sonuç elde etmektedir. Arayüzler ile DSS kullanımını kolaylaştırmaktadır. Bu arayüz tasarımlarına GUI (Graphical User Interface) denmektedir.

6.2. Karar Destek Sisteminin Türleri

DSS keni içinde kullanım amacına göre farklılıklar göstermektedir.

Veri tabanlı DSS: İçerisinde sadece veri depolamak için tasarlanmış DSS'dir. Sayısal ya da sözel verilerden oluşabilmektedir. Bu veriler mail, sensör, finansal, makine bilgisi, koordinat bilgisi, video, ses kaydı vb. kayıt altına alınabilecek her türlü veriden oluşabilmektedir.

Belge tabanlı DSS: Bilgilerin depolandığı verilerin birleştiği raporlar, evraklar ve belgelerin bir sistem altında yönetildiği yerdir.

Web tabanlı DSS: Online ortamlarda kullanım amaçlı tasarlanmış DSS'dir.

İletişim tabanlı DSS: İnsanlar arasında bilgi paylaşımını ve koordinasyonunu sağlama amaçlı tasarlanmış DSS'dir. Temelde verinin - bilginin bir noktadan başka bir noktaya aktarımını sağlamaktadır.


Burada bahsettiğimiz DSS türlerinin küçük bir kısmını oluşturmaktadır. DSS uygulama alanlarına baktığımızda her sektörde farklı amaçlarda kullanılan bir DSS karşımıza çıkmaktadır (Sol, 1983).

6.3. Karar Destek Sistemini Geliştirme Süreci

DSS zamanla geliştirilmesi gereken bir süreçtir. DSS içerisinde çok çeşitli sistemleri bir arada barındırabilir ve kullanıcının ihtiyaçlarına göre şekillendirilebilmektedir. DSS gelişim sürecini model ve hedef odaklı olarak ayırabiliriz. DSS'ni geliştirirken takip edilmesi gereken aşamalar şu şekilde sıralanabilir (Kamel, 1997).

- İhtiyacı tanımla: DSS sistemini oluşturmak için sorunlar analiz edilir ve hedefler belirtilir.
- Analiz: Son kullanıcıyı içerir. DSS gereksinimleri belirlenir. DSS mantıksal bir model oluşturur.
- Tasarım: Analiz sonucunda ortaya çıkan bilgiler doğrultusunda DSS yapısı tasarlanır. Adımları belirlenir. Burada amaç önerilen DSS'nin nasıl işleyeceğine dair teknik bir plan çıkarmaktır.
- Prototip tasarım ve test: Bu aşamada DSS çalışır bir durumda son kullanıcıya iletilmeden önceki halindedir. Bu süreçte önerilen DSS istenen ihtiyaç doğrultusunda geliştirilmiştir.
- Uygulama: Bu aşamada DSS son kullanıcıya sunulur ve geri bildirimler beklenir.
- Bakım ve geliştirme: Bu aşamada süreç içinde DSS oluşmuş, hataları ortadan kaldırmak ve işlevselliğini artırmak için bir süreç yönetilmektedir.

Çalışmada oluşturulan DSS hakkında detaylı bilgiye 7. bölümde yer verilmiştir. DSS çalışmasının diyagramı aşağıda verilmiştir.



Görsel 6.1. Karar destek sisteminin yapısı

6.4. Uygulamada Kullanılan Karar Destek Sisteminin Model Tabanındaki Diğer Yöntemleri

Modellerin hata ölçüt kriterleri

Geleceği %100 tahmin imkânı olmadığından dolayı tahmin yöntemlerinin hangisini kullanılırsa kullanılsın elde edilecek sonucun hata olasılığı olacaktır. Bu sebeple, her tahminin belli düzeyde bir hata oranı mevcuttur. Modelin tahmin başarısının belirlenmesi için hata ölçütlerine ihtiyaç vardır. Modellerin başarılarını kıyaslamak için kullanılan hata ölçüt kriterleri; MSE (Ortalama Kare Hatası), RMSE (Kök Ortalama Kare Hatası), MAPE (Ortalama Mutlak Yüzde Hata) ve MAD (Ortalama Mutlak Sapma) dır.

$$MSE = \frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2 \quad (6.1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2} \quad (6.2)$$

$$MAD = \left(\sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{n} \right| \right) \quad (6.3)$$

$$MAPE = \left(100 \frac{\sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right|}{n} \right) \quad (6.4)$$

Burada y_t gerçek değeri, $\hat{y}_t$ tahmin değerleri, n öngörülen dönem sayısını ifade eder. Formül 6.1, formül 6.2, formül 6.3 ve formül 6.4 vasıtasıyla ulaşılan değerlerin küçüklüğü en uygun modele ulaşılmasını sağlayacaktır.

ABC analizi

19. Yüzyıl İtalyan ekonomist Vilfredo Pareto tarafından istatistiksel olarak geliştirilen Pareto kuralının temel prensibi parçaların, satıcıların, ürünlerin, malzemelerin vb. gruplandırılmasına dayanmaktadır. Yani pareto yasası olarak bilinen prensip temelinde bir envanter (stok) kontrol yöntemidir (Akyol, 2011).

Pareto yasasına göre birçok projede toplam çabanın %20'si toplam sonucun %80'ini üretir. Pareto yasasına göre;

- Müşterilerin %20'si cironun %80'ini üretiyor.

- Ürünlerin %20'si cironun %80'ini yapıyor.
- Ürünlerin %20'si kârın %80'ini kazanıyor.
- Stoktaki malların %20'si stok değerinin %80'i kadardır.
- Stoklu ürünler için yapılan taleplerin %80'i malların sadece %20'si üzerindedir.

(Rusănescu, 2014)

Envanterde yer alan az sayıda ürünün, tüm envanter değerinin büyük bir kısmını oluşturmamasından dolayı ABC analizi ortaya çıkmıştır. ABC analizi envanter kontrolünün yanı sıra; satış ve dağıtım, kalite kontrolü, ürün türü, materyal tedariki ve üretim planlama sorunlarına da uygulanabilir. Bu yöntemin temelini oluşturan prensibin stok kontrolünde kullanımını ilk kez 1950'ler de General Electric firması geliştirmiştir (Akyol, 2011).

İşletmelerde tedarik zincirindeki stok fazlası ve eksikliği, tüketicilere ürün ve / veya hizmetlerin ulaşılabilirliğini etkileyebilir. Arz ve talep dengesini kurmak için stok dengesizliklerini kontrol etmek önemlidir. ABC analizi, ürünlerin %20'sinin satışların %80'ine katkıda bulunduğunu söyleyen pareto analizine dayanmaktadır. Envanterdeki öğelerin küçük bir kısmının maksimum satışlara katkıda bulunduğu anlamına gelir (Dhoka & Choudary, 2013).

Ürünlerin kategorizasyonunda kullanılan birkaç öge aşağıda belirtilmiştir.

1. Fiyat
2. Değer
3. Kritiklik
4. Kullanılabilirlik
5. Hareket
6. Öngörülebilirlik
7. Ağırlık

ABC analizi, farklı önem düzeylerine sahip olan ve farklı şekilde ele alınması veya kontrol edilmesi gereken bir dizi maddenin (faaliyetler, müşteriler, belgeler, envanter öğeleri, satış bölgeleri gibi) analizidir. ABC analizi, bir kuruluşun stok tutma birimlerini (SKU'lar) üç gruba ayırmasına izin verir: A en önemli, B önemli ve C en az önemli

olandır. Maddeleri gruplara ayırmanın amacı, her madde üzerinde uygun kontrol seviyeleri oluşturmaktır (Rusănescu, 2014).

A Sınıfı: Toplam envanter değerinin %80'ini temsil eden kalemlerdir. Genellikle envanterin çeşidine göre yaklaşık %15-20'sini oluşturur. %80'ini temsil eden kalemlerin envanterdeki optimizasyonuna gerçek zamanlı olarak dikkat ederek, envanter yönetimi maliyetlerinde minimum artış ile büyük bir olumlu etki mümkündür. A Sınıfının envanter yönetimi, belirli talep tahminleri ve ayrıntılı kayıt tutma gerektirir (Rusănescu, 2014).

B Sınıfı: Toplam envanter değerinin %15'ini temsil eden kalemlerdir. Genellikle envanterin çeşidine göre yaklaşık %30-35'ini oluşturur. %15'ini temsil eden kalemler genellikle dönem envanteri ile yönetilebilir ve resmi bir envanter sistemi ile yönetilmelidir (Rusănescu, 2014).

C Sınıfı: Toplam envanter değerinin %5'ini temsil eden kalemlerdir ancak envanterin çeşidine göre yaklaşık %50'sini oluşturur. C Sınıfı envanter maddelerine esnek bir denetim verilmelidir (Rusănescu, 2014).

ABC analizi uygulanırken ilk adımda ürünün yıllık kullanım miktarı ile birim maliyeti çarpılarak yıllık kullanım oranı hesaplanır. Envanterde yer alan her ürün için aynı işlem uygulanır. Envanter yer alan ürünler, toplam envanter değeri içindeki kümülatif yüzde oranlarına göre sıralanır ve A, B, C sınıflarına atanır (Akyol, 2011).

7. TALEP TAHMİNİ ÜZERİNE UYGULAMA

Bu bölümde, talep tahmini konusunda ARIMA, LSTM ve hibrit metotlardan karar destek sistemi üzerinden nasıl faydalanılabileceğinin ortaya konması amaçlanmıştır. Bu amaçla, bir perakende işletmesinden satış verilerinden faydalanmak suretiyle öncelikle satış verilerinin üzerinde ABC analizi uygulanıp buradan elde edilen verilerle ARIMA ve LSTM yönteminin kullanımı üzerinden talep tahmini gerçekleştirilmiştir. Daha sonra ise, bu iki yöntemin avantajlarının bir araya getirilmesi ve hibrit tahminleme metodundan yararlanılarak web tabanlı bir talep tahmini uygulaması karar destek sistemi olarak geliştirilmesi ile firmanın envanter yönetimine entegre edilmesi düşünülmüştür. Son olarak, bu proje Django Framework ve Python üzerinden hazırlanmıştır.

Uygulama bölümü iki aşamada hazırlanmıştır. Birinci aşamada karar destek sisteminin veri tabanında Pandas kütüphanesi ile Python işlemler yapılmış devamında model tabanı ARIMA, LSTM ve hibrit modeller üzerinde tahmin modelleri geliştirilmiş ve programlama kısmı burada Jupyter Notebook üzerinde çalışılmıştır. Bu çalışma açık kaynak kodlu olarak GitHub'a yüklenmiştir (GitHub). İkinci aşamada ise çalışmanın görsel karar destek sisteminin arayüz yönetimi için Django Framework üzerinde web tabanlı olarak hazırlanmıştır.

Burada geliştirmeye çalışılan uygulama işletmenin karar verme sürecinde etkili bir şekilde yararlanabileceği karar destek sisteminin ortaya çıkmasıdır.

7.1. İşletme Hakkında

Uygulamanın gerçekleşmekte olduğu işletme kuru gıda sektöründe faaliyetini sürdürmektedir. İşletmenin temel ürün gruplarını bakliyat, kuru meyve, çerezler ve aromatik yağlardan oluşmaktadır. İşletmenin temelde yer alan sağlıklı gıda prensibi nedeniyle stok minimum noktada tutulmaktadır. İşletmenin stok miktarları haftalık bazda hesaplanmaktadır.

Etkili bir envanter (stok) yönetimi için gelecekte oluşması muhtemel satışların tahminlenmesi işletmenin kısa ve uzun vadede yapacağı doğru yatırımlara karar vermesi adına önem teşkil etmektedir.

7.2. Veri Hazırlık Süreci

Projeye başlamadan önce işletmenin veri tabanından geçmişe yönelik satışların verileri alınmıştır. İşletmenin veri tabanından alınan verileri Python düzenleme sürecinden sonra ilerleyen adımlarda bütün ürün veya ürün gruplarına odaklanmak yerine ABC analizinden yararlanarak işletmenin gelir getirisi en yüksek ürünleri belirlenmeye çalışılmıştır.

ABC analizi temelinde pareto analizine dayanmakta olup %80 - %20 ilkesinden yola çıkılmıştır. Bu kısımda model hazırlık sürecinde hangi ürün grubu ve ürünlere odaklanmanın daha verimli olacağına karar verilmesi adına ABC analizinde A sınıfı ürünler %60, B sınıfı ürünler %25, C sınıfı ürünler %15 olarak alınmıştır.

Bu süreçte veri tabanından alınan verilerin daha kolay kullanılabilmesi adına Python'da Pandas kütüphanesinden yararlanılmıştır. Veriler üzerinde bütün çalışmalar bu ortamda gerçekleştirilmiştir. Burada yazılan kodlar görsel 7.1 ve görsel 7.2'de gösterilmiştir.

```
1 def ABC_segmentation(perc):
2     '''
3     A, B ve C tabanlı 3 sınıf oluşturmak ve
4     yüzdeleri miktar şu şekilde (A-60%, B-25%, C-15%) olarak belirlendi
5     '''
6     if perc > 0 and perc < 0.6:
7         return 'A'
8     elif perc >= 0.6 and perc < 0.85:
9         return 'B'
10    elif perc >= 0.85:
11        return 'C'
```

Görsel 7.1. ABC analiz kodları I

```
1 # Verilerin bir alt kümesini oluşturduk, her bir öğenin fiyatını ve miktarını bu veri setine ekledik
2 data_sub = dataABC[['SKU','Price','Quantity','FileType']][dataABC['FileType'] == 'Historical']
3 # SKU başına katkı maliyetinin (AddCost) sütununu oluşturmak. (data_sub['Quantity']/1000) gramı kilo donuşturmak
4 data_sub['AddCost'] = data_sub['Price'] * (data_sub['Quantity']/1000)
5 # Kümülatif maliyete göre sipariş
6 data_sub = data_sub.sort_values(by=['AddCost'], ascending=False)
7 # SKU başına kümülatif maliyetin (RunCumCost) sütununu oluşturmak
8 data_sub['RunCumCost'] = data_sub['AddCost'].cumsum()
9 # (TotSum) toplamın sütununu oluştur
10 data_sub['TotSum'] = data_sub['AddCost'].sum()
11 # (RunPerc) çalıştırma yüzde sütununu oluşturmak
12 data_sub['RunPerc'] = data_sub['RunCumCost']/data_sub['TotSum']
13 # (Class) sütununu oluşturmak
14 data_sub['Class'] = data_sub['RunPerc'].apply(ABC_segmentation)
```

Görsel 7.2. ABC analiz kodları II

ABC analizinin detaylı sonucu görsel 7.3’de gösterilmiştir.



	SKU	Price	Quantity	FileType	AddCost	RunCumCost	TotSum	RunPerc	Class
66	10000	1000.0	26230	Historical	23607.00	23607.00	330933.935	0.071334	A
8	10000	1000.0	2442	Historical	21978.00	45585.00	330933.935	0.137747	A
119	10000	1000.0	17519	Historical	21022.80	66607.80	330933.935	0.201272	A
56	10000	1000.0	12910	Historical	16783.00	83390.80	330933.935	0.251986	A
131	10000	1000.0	26988	Historical	16192.80	99583.60	330933.935	0.300917	A
34	10000	1000.0	11270	Historical	12171.60	111755.20	330933.935	0.337696	A
7	10000	1000.0	13696	Historical	11367.68	123122.88	330933.935	0.372047	A
129	10000	1000.0	8193	Historical	8193.00	131315.88	330933.935	0.396804	A
35	10000	1000.0	6593	Historical	7911.60	139227.48	330933.935	0.420711	A
16	10000	1000.0	5091	Historical	6109.20	145336.68	330933.935	0.439171	A
5	10000	1000.0	9308	Historical	6050.20	151386.88	330933.935	0.457453	A
134	10000	1000.0	6587	Historical	5928.30	157315.18	330933.935	0.475367	A
118	10000	1000.0	6227	Historical	5915.65	163230.83	330933.935	0.493243	A
137	10000	1000.0	9333	Historical	5599.80	168830.63	330933.935	0.510164	A
6	10000	1000.0	7920	Historical	5148.00	173978.63	330933.935	0.525720	A
80	10000	1000.0	9291	Historical	4645.50	178624.13	330933.935	0.539758	A
23	10000	1000.0	4525	Historical	4525.00	183149.13	330933.935	0.553431	A
79	10000	1000.0	4659	Historical	4426.05	187575.18	330933.935	0.566806	A
105	10000	1000.0	4642	Historical	4177.80	191752.98	330933.935	0.579430	A
100	10000	1000.0	5835	Historical	4084.50	195837.48	330933.935	0.591772	A
33	10000	1000.0	3807	Historical	3807.00	199644.48	330933.935	0.603276	B
61	10000	1000.0	12844	Historical	3724.76	203369.24	330933.935	0.614531	B
109	10000	1000.0	2410	Historical	3615.00	206984.24	330933.935	0.625455	B
89	10000	1000.0	9733	Historical	3309.22	210293.46	330933.935	0.635455	B
64	10000	1000.0	16163	Historical	3232.60	213526.06	330933.935	0.645223	B

Görsel 7.3. ABC analizinin sonucu


- A sınıfı ürünler envanterin %14'lük bir kısmını oluştururken genel envanter değerinin %60'ını temsil eder.
- B sınıfı ürünler envanterin %23'lük bir kısmını oluştururken genel envanter değerinin %25'ini temsil eder.
- C sınıfı ürünler envanterin %64'lük bir kısmını oluştururken genel envanter değerinin %15'ini temsil eder.

ABC analizi sonucu ortaya çıkan özet tablo 7.1’de belirtilmiştir.

Tablo 7.1. ABC analizinin özet tablosu

Class	Total SKU	Total Cost (MKD)	Quantity	Cost Percentage
A	20	195837	14%	60%
B	33	83872	23%	25%
C	93	51224	64%	15%
Total	146	330933	100%	100%

Bu aşamada ABC analizi sonucu alınan veriler üzerinden işletme ile yapılan görüşmeler sonucunda çalışmanın model arayüz yönetiminde test ve kaynak veri seti olarak kullanılacak ürün grubu ve ürün seçimi yapılmıştır. Seçilen ürünlerde veri işleme, işletmenin talebi doğrultusunda haftalık bazda düzenlenmiştir. Firma ve ürün bilgisi rekabet unsurları açısından firmanın isteği üzerine saklı tutulmaktadır. İlgili veri seti, tez içeriğinde belirlenen modellerde kullanılmak üzere bir dizi haline getirilmiştir. İşletmenin son dönemde aylık gerçekleşen verileri görsel 7.4’de gösterilmiştir.



Görsel 7.4. *Temsil edilen verilere ait zaman veri grafiği*

Verilerin sayısal olarak büyük olmasından dolayı x (1000) oranında küçültülerek çalışma yapılmıştır.

Tahmin uygulamalarında kullanılan veri setleri, test ve eğitim verileri olmak üzere ikiye ayrılır. Literatür çalışmaları incelendiğinde eğitim veri seti ve test veri setlerinin belirlenmesinde %70 eğitim, %30 test veya %80 eğitim ve %20 test şekli kabul görmüştür. Bu çalışmada yaygın olarak kullanılan ve yapılan değerlendirmeler sonucunda zaman serisi zaman bazlı bölünmüştür. Eğitim veri seti %70 ve test veri seti %30 olarak belirlenmiştir. Opsiyonlu olarak model tabanında değiştirilebilir olarak bırakılmıştır.

Model yönetim sisteminde yapay sinir ağları yöntemi seçilmişse eğitim süresince dikkat edilmesi gereken önemli bir unsur da eğitim setinin daha fazla veri oluşturmuş olmasıdır. Burada genel varılacak sonuç eğitim seti dışında kalan verilerin yani test verilerinin genel örneği temsil etme gücünün denetlenmesidir.

Karar destek sisteminin veri tabanında kullanılan veriler, zaman serisi olduğundan dolayı model tabanında kullanılacak tahminleme modellerinin zaman serilerinin doğrusal ve doğrusal olmayan yapılarından kaynaklı olarak seçilen modeller de bu yönde oluşmuştur. Zaman serisinin tahminlemesinde kullanılan doğrusal yöntemlerden biri olan ARIMA metodu ve ANN doğrusal olmayan yöntemlerden biri olan LSTM metodu ile

çalışılmıştır. Çalışmanın devamında bu iki yöntemin ortak olarak kullanıldığı hibrit bir model seçilmiştir. Hibrit modellerin oluşmasında temel amaç iki modelin dezavantajlarını birbirlerine kırdırarak gerçeğe daha yakın bir tahminleme yapmaktır.

Bu çalışmanın diğer bir adımı olarak web tabanlı karar destek sistemi uygulamasının geliştirilmesi hedeflenmiştir. Bunun sonucunda Python 3.7 programlama dilinde hazırlanmış olan bütün çalışma, yine bir Python Framework olan Django 3.0 üzeri web tabanlı bir yazılıma dönüştürülerek kullanımı kolay olması adına bir kullanıcı arayüzü geliştirilmiştir. Bu çalışmada kullanılan kütüphaneler Ek-1’de verilmiştir.

7.3. Tahmin Üretim Süreci ve Kullanılan Modeller

Karar destek sisteminin model yönetim sürecinde kullanılan yöntemler ve süreçleri hakkında bilgi verilmiştir.

7.3.1. ARIMA uygulaması

Bu aşamada Bütünleşik Otoregresif Hareketli Ortalama - ARIMA (Autoregressive Integrated Moving Average) doğrusal model olarak belirlenmiştir. ARIMA doğru parametrelerin seçilmesi sürecinde ve modellerin her birinin ayrı ayrı incelenmesinin kolaylaştırılması adına ARIMA için geliştirilmiş olan bir Python kütüphanesi pmdarima bulunmaktadır. Uygulamada bir ürüne odaklanılmış olsa da diğer ürünler için farklı parametrelere ihtiyaç olması durumunda ve bu parametreleri deneme yanılma yöntemleri bulunması yerinde otomatikleştirilmiştir.

Doğru ARIMA modelinin seçiminde durağan ARMA, durağan olmayan ARIMA ve mevsimsel SARIMA olmak üzere farklı model ve yaklaşımlar vardır. Doğru model seçiminde alınabilecek parametreler ARIMA ve ARMA için (p,d,q) değer p otoregresif modelin derecesi (AR), d fark alma derecesi, q hareketli ortalama modelinin derecesidir (MA). SARIMA için (p,d,q) değerlerinin yanında (s,P,D,Q) P modelin mevsimsel otoregresif ve Q mevsimsel hareketli ortalama derecelerini temsil etmektedir. D serinin durağanlığının sağlanabilmesi için sırasıyla kaçınıcı dereceden standart ve mevsimsel farkların alındığını ifade etmektedir. s mevsimsel farkın periyodik aralığını göstermektedir.

Seçilen ürün için yapılan analiz sonucu görsel 7.6’da gösterilmiştir ve Auto ARIMA’dan yararlanılmıştır. İlgili kodlar görsel 7.5 verilmiştir ve doğru modelin bulunması kolaylaştırılmıştır.

```
1 auto_arma(df, start_p=1, start_q=1,
2           max_p=3, max_q=3, m=12,
3           start_P=0, seasonal=True,
4           d=1, D=1, trace=True,
5           error_action='ignore',
6           suppress_warnings=True,
7           stepwise=True).summary()
```

Görsel 7.5. Auto ARIMA ile ilgili kodlar


SARIMAX Results

Dep. Variable:	y	No. Observations:	41			
Model:	SARIMAX(0, 1, 1)x(0, 1, 1, 12)	Log Likelihood	-215.913			
Date:	Sat, 09 May 2020	AIC	439.826			
Time:	23:52:06	BIC	445.155			
Sample:	0	HQIC	441.455			
	- 41					
Covariance Type:	opg					
	coef	std err	z	P> z	[0.025	0.975]
intercept	-3.6084	15.777	-0.229	0.819	-34.532	27.315
ma.L1	-0.9990	16.832	-0.059	0.953	-33.988	31.990
ma.S.L12	-0.9928	16.632	-0.060	0.952	-33.590	31.605
sigma2	1.726e+05	4.14e-05	4.17e+09	0.000	1.73e+05	1.73e+05
Ljung-Box (Q):	21.90	Jarque-Bera (JB):	0.78			
Prob(Q):	0.74	Prob(JB):	0.68			
Heteroskedasticity (H):	1.30	Skew:	-0.26			
Prob(H) (two-sided):	0.70	Kurtosis:	3.63			

Görsel 7.6. Auto ARIMA sonucu


Görsel 7.6’da yer alan Auto ARIMA sonucunda elde edilen ARIMA modeli SARIMAX (0,1,1) x (0,1,1,12) olmuştur. Auto ARIMA model özeti incelendiğinde veri setini çözmek için en uygun modelin SARIMAX olacağı ve verilerin içinde sezonsal bir ilişki olabileceği gözlemlenmiştir. Doğru tahminler üretebilmek için zaman serilerini içeren veri kümelerinde trendler ya da döngüler olabilir.

Bu adımdan sonra ise elde edilen verilerin daha okunaklı olması için görsel 7.7’de karşılaştırma grafiği hazırlanmıştır.



Görsel 7.7. ARIMA sonuç grafiği

Sonuçlar incelendiğinde, gerçek veriler ile tahminlenen verilerin birbiri ile örtüştüğü gözlemlenmektedir. Grafikte görülen, verilerin yakınlık değerlerinin yanı sıra yönlerinin kırılması ve benzer olması net gözlemlenebilmektedir. Burada kullanılan modelde, ARIMA MSA: 207.45, RMSE: 14.403, MAD: 0,32 ve MAPE: 0,067 olarak gerçekleşmiştir. Bu modelde gerçek veriye yakın değerler üretebiliyor olmamız uygulanan modelin başarısını göstermektedir.



Görsel 7.8. ARIMA ile gelecek dönemlerde yapılan tahminler

Çalışmanın devamında ise elde edilen model geleceğe yönelik olarak 5 dönemlik tahmin yaptırılmış ve elde edilen sonuçlar görsel 7.8’de verilmiştir.

7.3.2. LSTM uygulaması


Uygulama bölümünün bu kısmında, tahminleme metodu olarak LSTM kullanılmıştır. Genel olarak ANN’nin eğitim süresince çok fazla veriye ihtiyaç duyuyor olması çalışma için dezavantaj teşkil etmektedir. Ama literatürde LSTM metoduyla az veri kullanılarak iyi sonuçlar verdiği durumlar da gözlemlenmektedir. Bu sebeple, hibrit model için LSTM tercih edilmiştir.

Çalışmada kullanılan LSTM modeli ile ilgili kodlar görsel 7.9’da verilmiştir. KERAS’da LSTM için geliştirilmiş API’den yararlanılmıştır. Burada model aktivasyon fonksiyonu olarak RELU seçilmiştir. Farklı aktivasyon fonksiyonlarında da deneme yapılmış olmakla birlikte, yapılan denemeler sonrasında en iyi sonucu veren RELU aktivasyon fonksiyonu seçilmiştir.


```
18 lstm_model = Sequential()  
19 lstm_model.add(LSTM(100, activation='relu', input_shape=(n_input, n_features)))  
20 lstm_model.add(Dense(1))  
21 lstm_model.compile(optimizer='adam', loss='mse')  
22  
23  
24 lstm_model.summary()
```

Görsel 7.9. LSTM model mimarisi kodları

Eğitim verisi %70 olarak seçilmiş ve 1000 epoch adım kullanılmıştır. Çıkan sonuçlardan önce görsel 7.10’daki LSTM kayıp grafiği ortaya çıkmıştır.




Görsel 7.10. LSTM kayıp grafiği



Görsel 7.11. LSTM tahmin test grafiği

Görsel 7.11’de sonuç verileri gerçek verilerle karşılaştırıldığında elde edilen sonuçların grafiği yer almaktadır. Gerçekleşen duruma yakın kırılımlar vermesi ile LSTM MSE: 183.932, RMSE: 13.561, MAD: 0.32 ve MAPE: 0.04 olarak karşımıza çıkmaktadır. Doğrusal olmayan bir yapıya sahip olan LSTM’nin küçük bir veri setine rağmen iyi bir sonuç elde ettiği görülmektedir.



Görsel 7.12. LSTM ile gelecek dönemlerde yapılan tahminler

Çalışmanın devamında ise elde edilen modele geleceğe yönelik olarak 5 dönemlik tahmin yaptırılmış ve elde edilen sonuçlar görsel 7.12’de verilmiştir.

7.3.3. Hibrit model

Çalışmanın bu bölümünde LSTM ve ARIMA’dan oluşan hibrit model yaklaşımından yararlanılmıştır. Çalışmada kullanılan hibrit yaklaşım sırasıyla ARIMA tahminlerini ve LSTM tahminlerini üretmektedir. Ardından hibrit tahmin oluşturmak için ARIMA ve LSTM hibrit modeldeki ağırlıklarına karar verilmektedir. Kullanılan formül hibrit model bölümünde anlatılmaktadır. Formül karar destek sisteminin model tabanına görsel 7.13’deki gibi aktarılmıştır.


```

1 def GetHybrid(Arima_MSE,LSTM_MSE,Arima_Data,LSTM_Data):
2
3     #LSTM Wigth
4     LSTM_wigth = (1-(LSTM_MSE/(LSTM_MSE+Arima_MSE)))*2
5     LSTM_wigth
6
7     #Arima Wigth
8     Arima_wigth = 2-LSTM_wigth
9     Arima_wigth
10
11     Final_Prediction=(Arima_Data*Arima_wigth+LSTM_Data*LSTM_wigth)/2
12
13     return Final_Prediction


```

Görsel 7.13. Hibrit formülünün Pyhton karşılığı

Formül bilgisayar ortamına aktarıldıktan sonra görsel 7.14’de görüldüğü üzere veriler test verisi ile karşılaştırılmıştır.



Görsel 7.14. Hibrit karşılaştırma grafiği



Görsel 7.15. ARIMA, LSTM ve Hibrit Model, test verisi ile karşılaştırılması

Çalışmanın elde edilen hibrit sonuçları görsel 7.15’de incelenebileceği üzere bazı dönemlerde kesişimler göstermiş bazı dönemlerde farklılıklar ortaya çıkmıştır. Bunun iki sebepten kaynaklı olduğu düşünülmektedir. Birinci sebep olarak veri setinin boyutu, ikinci sebep ise ekonomik olaylarda yaşanan değişiklikler ya da ürüne olan talepte ani değişiklikler olarak düşünülmektedir. Çalışmada talep tahminleri haftalık bazda gelen verilerden alınmıştır. İşletme yetkilileri ile yapılan görüşmelere istinaden ürünleri aylık bazda sipariş veriyor olmaları tahminlerin aylık bazda doğruluk oranını arttırmaktadır.


Tablo 7.2. Uygulama sürecinde seçilen ürünlerin başarı kriterleri tablosu

Ürünler					
Ürün	Model	MSE	RMSE	MAD	MAPE
A Ürünü	ARIMA	207.456	14,403	0,322	0,067
	LSTM	183.992	13,561	0,329	0,051
	Hybrid	121.862	11,039	0,290	0,042
B Ürünü	ARIMA	257.443	16,045	0,404	0,084
	LSTM	164.439	12,823	0,333	0,042
	Hybrid	146.714	12,113	0,307	0,055
C Ürünü	ARIMA	193.463	13,909	0,103	0,021
	LSTM	123.515	11,114	0,263	0,033
	Hybrid	90.975	9,538	0,087	0,015

Yukarıda yer alan tablo 7.2’de farklı ürünler için geliştirilen model ve ürünlere denemelerden elde edilen sonuçlar verilmiştir. Model kimi zaman doğruluk oranı gerçek verilere yakın olsada kimi zaman farklı ürünlerde kötü sonuç vermiştir. Burada aslında ürünler aynı sektöre veya aynı ürün grubuna ait olsa da her koşulda doğru sonuç veren tek bir model olmadığı gözlenmiştir. Parametrelerde değişiklikler yapılarak iyileştirmeler sağlanmıştır. Farklı faktörlerin ürün talebine etkisinin olduğu işletme yetkilileri ile görüşmelerde dile getirilmiştir. Elde edilen bulgular ışığında A ürünü için hibrit MAPE değeri %4 iken ARIMA ve LSTM için MAPE %5 ve %6 değerleri kıyaslandığında hibrit model daha iyi bir sonuç vermiştir. Bu gözlem diğer ürünler içinde gerçekleşmiştir. Tahmin üretimi sürecinde hibrit bir modelin seçimi tekil modeller ile kıyaslandığında daha doğru olduğu gözlenmiştir.

7.3.4. Blok zincir verileri üzerine modelin denenmesi

Bu çalışmada kullanılan model ürünler talep tahmini üzerine kurulmuş olsa da, farklı veri setleri üzerinde de tahmin edilebilirliği ölçülmek istenmiştir. Bu nedenle kriptopara piyasalarında nasıl sonuç elde edileceği gözlenmesi adına kriptopara birimlerinden Bitcoin 2018-2020 yılları arasındaki piyasa değeri verileri üzerine günlük bazda açılış, kapanış, gün içinde en yüksek ve en düşük değerleri elde edilmiştir. Bu veriler üzerinden ortalaması alınmıştır. İkinci aşamada veriler günlük bazdan aylık baza dönüştürülmüştür. Dönüştürme sonucunda elde edilen grafik 7.16’da yer almaktadır.




Görsel 7.16. 2018 Ocak – 2020 Mart verileri

Veriler üzerinde ilk önce ARIMA uygulanmış daha sonra LSTM modeli denenmiştir. 4 dönem ileriye doğru tahmin yapılması çalışılmıştır. Elde edilen sonuçlar tablo 7.3’de verilmiştir.

Tablo 7.3. Bitcoin tahmin sonuçları

Week	Bitcoin	LSTM_Predictions	Arima_Predictions	Hybrid_Predictions
2019-08-31	10619.831694	8062.077442	11301.260403	9826.845544
2019-09-30	9791.958833	7428.737309	10809.114820	9270.430870
2019-10-31	8380.389355	7112.013442	10655.219919	9042.419302
2019-11-30	8351.114500	6989.119853	10407.514237	8851.525725
2019-12-31	7253.487581	6937.526665	7970.508871	7500.314895
2020-01-31	8328.280726	6916.402935	7956.117742	7482.859213
2020-02-29	9643.732586	6907.685087	7675.232993	7325.859694
2020-03-31	6900.290081	6904.095309	8020.518226	7512.343616
2020-04-30	7192.696250	6902.616294	9293.641153	8205.291831

Elde edilen sonuçlar incelendiğinde ARIMA ve LSTM kıyaslandığında daha iyi performansın sergilendiği MAPE değerlerine bakılmalıdır. ARIMA’da MAPE değeri %16,53 iken LSTM’de %14,82 şeklinde gözlemlenmektedir. Hibrit modelde ise %9,69 değeri ile ARIMA ve LSTM’den çok daha iyi performans sergilediği görülmektedir. MAPE değerlerine bakıldığında hibrit model ARIMA’ya göre %41 ve LSTM’ye göre %34 daha iyi bir performans sergilemektedir.




Görsel 7.17. Bitcoin, ARIMA, LSTM ve Hibrit model tahmin grafiği

7.4. Karar Destek Sisteminin Arayüzleri


Bu kısımda, çalışmanın ilerleyen vadede işletmenin mevcut alt yapısına entegrasyonunun sağlanabilmesi için karar destek sistemi olarak web tabanlı portal düzenlenmiştir. Burada temel amaç işletmenin karar destek sistemi olarak kullanmasını sağlamaktır. Çalışma veri tabanına entegrasyon süresince işletmenin mevcut sistemi ile haberleşmesi için altyapısı hazırlanmıştır. Ama işletmenin mevcut altyapı

sağlayıcısındaki güvenlik nedeni ile izin alınamamasından kaynaklı olarak çalışma karar destek sistemi halinde kullanılmak üzere işletmeye uygun bir şekilde düzenlenmiştir. Görsel 7.18’de Django web portalının arayüzü gösterilmiştir.




Görsel 7.18. Django web portalı arayüzü


Çalışmanın arayüzü oldukça basit tutulmuştur. Burada amaç kullanıcının hızlı bir şekilde istediği ürün hakkında tahmin oluşturabilmesidir. Hazırlanan web portalının ilerleyen dönemlerde GitHub üzerinden açık kaynak kodlu olarak sunulması düşünülmüştür. Projenin arayüzünü tanımlamak gerekirse, tahminleme yapmak istediğiniz veri setini ilk önce portala yükleyerek başlıyoruz. Burada yüklemenin ardından start düğmesine basıldığında geriye kalan bütün işlem otomatik olarak başlıyor. Bu kısım ilerleyen vadede kullanıcının istekleri üzerine şekillendirilebilir. Start butonuna basıldıktan sonra ARIMA, LSTM ve hibrit modelleri arka tarafta çalışıp 5 adım sonrasını hesaplamaya çalışarak bir tahminleme üretmeye çalışmaktadır. Karar destek sisteminin model tabanı bir önceki kısımlarda ayrıntılı olarak açıklanmıştır. Elde edilen sonuçlar kullanıcıya rapor olarak sunulmaktadır. Kullanıcıya sunulan sonuçlar ise örnek olarak görsel 7.19, görsel 7.20, görsel 7.21 ve görsel 7.22’de gösterilmiştir.




Görsel 7.19. *Yüklenen veri setinin ekranı*



Görsel 7.20. *ARIMA tahmin ekranı*




Görsel 7.21. LSTM tahmin ekranı




Görsel 7.22. Hibrit tahmin ekranı

Manuel düzenleme ekranları



Görsel 7.23. ARIMA manuel olarak parametreleri ayarlama ekranı


Görsel 7.23’de yer alan ekran görüntüsü ARIMA’nın parametreleri üzerinde manuel olarak ayar yapmak için tasarlanmıştır. Burada p parametresi otoregresif modelin derecesi (AR), d parametresi fark alma derecesi, q parametresi hareketli ortalama modelinin derecesini etkiler.



Görsel 7.24. LSTM manuel olarak parametreleri ayarlama ekranı

Manuel olarak düzenlenebilenler aktivasyon fonksiyonunun içinde RELU, Sigmoid ve Lineer olmak üzere üç farklı şekilde seçilebilir. Epoch: Model eğitilirken verilerin tamamı aynı anda eğitime katılmaz. Eğitim setinde bölümler halinde eğitimde yer alırlar. Bu nedenle kaç Epoch yapabileceğimiz burada seçim yapabilmekteyiz. 10 ile 3000

aralığında tercih yapılabilir. Hidden Layer: Sinir ağı kaç katmandan oluşacak ve Neurons katmanlarda kaç adet bağlantı noktası olacağına karar verilir.



Görsel 7.25. Hybrid modelde ARIMA ve LSTM manuel olarak ayarlanması

Görsel 7.25’de uygulama için geliştirilmiş iki farklı modelde seçim yapılabilir. Manuel seçimde ARIMA ve LSTM ağırlıklarının modelde ne kadar etkisinin olacağı seçilebilmektedir.

8. SONUÇ VE ÖNERİLER

8.1. Sonuç

Rekabet, değişimin önemli bir parçası ve her sektörü etkileyen büyük bir faktördür. Rekabetin genel tanımına bakıldığında, üstünlük sağlama amacı ile rakiplere karşı yürütülen stratejik etkinliklerin bütünü olduğu görülmektedir. İşletmeler hayatlarını sürdürebilmeleri için rekabet koşullarında elde edebilecekleri bütün avantajlara ve stratejilere ihtiyaç duyarlar. Geleceğe yönelik olarak yapılabilecek doğru bir tahmin işletmenin rakiplerinin önüne geçmesini sağlayacaktır.

Çalışmada konu olan işletme perakende sektöründe gıda üzerine satış faaliyeti sürdürmektedir. Uygulamada kullanılan veriler işletmenin 2019-2020 yılları satış miktarlarını kapsamaktadır. Elde edilen satış verileri matematiksel bir formül ile oransal olarak değiştirilmiştir. Uygulama satış verileri üzerinden talep tahmini yapmak üzere hazırlanmıştır. Çalışma boyunca elde edilen bulgular firma yetkilileri ile paylaşılmıştır.

Uygulamanın araştırma süresince talep tahmini yaklaşımlarının nasıl entegre edilebileceği, üzerinde durulmuş doğrusal bir yöntemin doğrusal olmayan bir yöntemle daha iyi sonuçlar elde edilebileceği gözlemlenmiştir. Çalışma boyunca literatür taramalarında farklı zaman serisi problemleri ile farklı yöntemler incelenmiştir. Çalışmanın ilk evrelerinde yapay sinir ağları ile bir model geliştirilmiştir. Araştırma sonuçlarında ARIMA ve LSTM modellerinin birlikte kullanılmasına karar verilmiştir. ARIMA ve LSTM modelleri tek tek ele alınmıştır. Çalışmanın ilerleyen süreçlerinde hibrit modeller üzerinde incelemeler yapılmıştır. Nihai sonuç olarak ARIMA ve LSTM modellerinin dezavantajlarını birbirlerine kırdırarak hibrit bir model ile sonuçlar elde edilmiştir. Çalışma süresince farklı veri setleri ile çalışmalar da yapılmıştır.

Çalışmaya konu olan veri seti içerisinde 8 farklı kategoride 150 ürünün ve bu ürünlerin günlük bazda satış miktarları yer almaktadır. Çalışmanın başlangıcında işletmeden alınan veri seti, veri analizi için düzenlenmiştir. Düzenlenen veri seti ABC analizi uygulanarak ürünlerin önem sırası belirlenmiş ve ürünler cirolarına göre sıralanmıştır. ABC analizi sırasında elde edilen sonuçlara göre test ürünleri belirlenmiş ve bu ürünler üzerinde uygulama hazırlanmıştır. Çalışma iki aşama olarak ele alınmıştır. Birinci kısım modellerin geliştirilmesi, ikinci kısım ise modellerin web tabanlı bir yazılım

haline getirilmesidir. ARIMA, LSTM ve hibrit model için Python 3.7 üzerinde kodlama yapılmıştır. Modellerin başarı kriterleri MSE, RMSE, MAD ve MAPE olarak seçilmiştir. Çalışmanın ikinci kısmında, karar destek sisteminin bir bileşeni olarak arayüz tasarımları için Django 3.0 üzerinde bir tasarım ve uygulama çalışması gerçekleştirilmiştir. Hazırlanan arayüz geliştirilmeye açık olup ilerleyen süreçte ARIMA, LSTM ve hibrit parametrelerine değişikliği bu arayüzler üzerinden yapılabilir durumdadır.

Çalışmanın sonucu olarak, ele alınan zaman serileri içerisinde birden fazla faktörün olduğu ve bu faktörlerin arasında doğrusal ve doğrusal olmayan örüntüler içerdiği, yapılan analizler sonucunda ortaya konulmuştur. Hibrit bir modelin zaman serilerini çözümlmek için kullanılmasının avantajlı olacağı gözlemlenmiştir. Literatürde hibrit model yaklaşımlarının farklı birçok yöntemin birleşimi ile ele alınabildiği gözlenmekle birlikte çalışma kapsamında ARIMA ve LSTM modellerinin birleşiminden oluşan hibrit bir model kullanılmıştır. İşletme ile yapılan görüşmeler sonrasında ortaya çıkan sonuçların tutarlılığı ve olası talebi tahmin etmek amacı ile geliştirilen web tabanlı karar destek sisteminin uygunluğu ile ilgili geri dönüşler alınmıştır.

8.2. Öneriler

Çalışmanın uzantısı olarak;

- Parametrelerin optimal anlamda seçilebilmesi için literatürde yer alan yaklaşımların karar destek sistemine eklenmesi sayesinde farklı ürünler için özel tahmin modelleri oluşturulabileceği,
- Geliştirilen hibrit modelin entegre bir API haline getirilerek farklı sistemlerde ve projelerde kullanılabileceği,
- Karar destek sisteminin stok sistemi ile entegre edilerek elde edilen tahminlerin olası durumlara karşılık raporlar sunulabilecek bir yapıya kavuşturulabileceği düşünülmektedir.

KAYNAKÇA

- Abbasimehr, H., Shabani, M., & Yousefi, M. (2020). An optimized model using LSTM network for demand forecasting. *Computers & Industrial Engineering*, 143.
- Adıyaman, F. (2007). *Talep Tahmininde Yapay Sinir Ağlarının Kullanılması*. Yüksek Lisans Tezi. İstanbul: İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Akyol, B. (2011). *Çok Kriterli ABC Stok Sınıflandırma Problemi İçin Yeni Bir Yaklaşım*. Yüksek Lisans Tezi. Kayseri: Erciyes Üniversitesi, Fen Bilimleri Enstitüsü.
- Aladag, C., Eğrioğlu, E., & Kadılar, C. (2009). Forecasting nonlinear time series with a hybrid methodology. *Applied Mathematics Letters*, 22, 1467–1470.
- Alexouda, G. (2005). A User-friendly Marketing Decision Support System for the Product Line Design Using Evolutionary Algorithms. *Decision Support Systems*, 38, 495 – 509.
- Arnott, D., & Pervan, G. (2008). Eight Key Issues for the Decision Support Systems Discipline. *Decision Support Systems*, 44, 657–672.
- Ateşoğlu, A. (2015). *ARIMA Ve Yapay Sinir Ağları (YSA) Kullanılarak Hibrit Tahmin Modeli Geliştirilmesi*. Yüksek Lisans Tezi. Ankara: Başkent Üniversitesi, Fen Bilimleri Enstitüsü.
- Babu, C., & Reddy, B. (2014). A moving-average-filter-based hybrid ARIMA–ANN model for forecasting time series data. *Applied Soft Computing*, 23, 27-38.
- Ballı, M. (2014). *Yapay Sinir Ağları İle Talep Tahmini Ve Gıda Sektöründe Uygulanması*. Yüksek Lisans Tezi. İstanbul: Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü.
- Baughman, M., Haas, C., Wolski, R., Foster, I., & Chard, K. (2018). Predicting Amazon Spot Prices with LSTM Networks. *Scientific Cloud Computing*, 18, 1-7.
- Box, G., Jenkins, G., Reinsel, G., & Ljung, G. (2016). *Time Series Analysis Forecasting and Control*. Amerika Birleşik Devleti: John Wiley & Sons Inc. .
- Bozkır, A. (2009). *OLAP ve Veri Madenciliği Teknolojilerinden Yararlanılarak Web Tabanlı Bir Karar Destek Sisteminin Gerçekleştirilmesi*. Yüksek Lisans Tezi. Ankara: Hacettepe Üniversitesi, Fen Bilimleri Enstitüsü.

- Çayıroğlu, İ. (2020, 04 10). *Karabük Üniversitesi, Mühendislik Fakültesi*. <http://www.ibrahimcayiroglu.com/Dokumanlar/IleriAlgoritmaAnalizi/IleriAlgoritmaAnalizi-5.Hafta-YapaySinirAglari.pdf> adresinden alındı
- Çelik, L. (2006). *Karar Destek Sistemlerinin Karar Verme Sürecindeki Rolü (Otomotiv Sektöründe Faaliyet Gösteren Bir İşletmede İncelenmesi)*. Yüksek Lisans Tezi. İstanbul: Marmara Üniversitesi, Sosyal Bilimler Enstitüsü.
- Choi, H. (2018). *Stock Price Correlation Coefficient Prediction with ARIMA-LSTM Hybrid Model*. Yüksek Lisans Tezi. Korea: Korea University, Dept. of Business Administration.
- Dhoka, D., & Choudary, Y. (2013). ABC Classification for Inventory Optimization. *IOSR Journal of Business and Management*, 15 (1), 38-41.
- Dizman, H., & Özen, E. (2017). Küçük İşletmelerde Karar Destek Sistemlerinin Farkındalığı Üzerine Bir Araştırma: Yerel Bir Yaklaşım (Ege Bölgesi). *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 137-153.
- Faruk , D. (2010). A hybrid neural network and ARIMA model for water quality time. *Engineering Applications of Artificial Intelligence*, 23, 586-594.
- Firmino, P., Neto, P., & Ferreira, T. (2015). Error modeling approach to improve time series forecasters. *Neurocomputing*, 153, 242-254.
- GitHub. (tarih yok). https://github.com/seoriz/Arima_LSTM_Hybrid.git adresinden alındı
- Hocaoğlu, F., Kaysal, K., & Kaysal, A. (2015). Yük Tahmini için Hibrit (YSA ve Regresyon) Model. *Akademik Platform*, 3 (2), 33-9.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9 (8), 1735-1780.
- Hugh, C., Coleman, S., & Kerr, D. (2019). Forecasting Day-ahead Electricity Prices with a SARIMAX Model. *IEEE Symposium Series on Computational Intelligence (SSCI)* (s. 1523-1529). China: IEEE.

- Kamel, S. (1997). DSS for Strategic Decision Making . J. Liebowitz, & M. Khosrowpour içinde, *Cases on Information Technology Management in Modern Organizations* (s. 168-171). London: Idea Group Publishing .
- Kara, A. (2019). Uzun-Kısa Süreli Bellek Ağı Kullanarak Global Güneş Işınımı Zaman Serileri Tahmini. *Gazi Üniversitesi Fen Bilimleri Dergisi*, 7 (4), 882-892.
- Karaatlı, M., Helvacıoğlu, Ö., Ömürbek, N., & Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi İle Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8 (17), 88-90.
- Karahan, M. (2011). *İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu İle Ürün Talep Tahmini Uygulaması*. Doktora Tezi. Konya: Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü.
- Kaya, L. (2015). *Durağan Olmayan Zaman Serilerinde Alternatif Tahmin Yöntemlerinin Karşılaştırmalı Olarak İncelenmesi*. Doktora Tezi. Şanlıurfa: Harran Üniversitesi, Fen Bilimleri Enstitüsü.
- Kayhan, S. (2019). *Sürekli Üretim Sistemleri İçin Talep Tahmini ve Karar Destek Sistemi Geliştirilmesi: Kimya Sektöründe Örnek Bir Uygulama*. Yüksek Lisans Tezi. Adana: Çukurova Üniversitesi, Fen Bilimleri Enstitüsü.
- Kendel, M. (1973). *The Advanced Theory of Statics*. London: Charles Griffin.
- Khashei, M., & Bijari, M. (2010). An Artificial Neural Network (p,d,q) Model for Timeseries Forecasting. *Expert Systems with Applications*, 37, 479-489.
- Khashei, M., & Bijari, M. (2011). A Novel Hybridization of Artifical Neural Networks and ARIMA Models for Time Series Forecasting. *Applied Soft Computing*, 11, 2664-2675.
- Khashei, M., & Bijari, M. (2011). Which Methodology is Better for Combining Linear and Nonlinear Models for Time Series Forecasting? *Journal of Industrial and Systems Engineering*, 4 (4), 265-285.
- Khashei, M., Bijari, M., & Ardali, G. (2012). Hybridization of Autoregressive Integrated Moving Average (ARIMA) with Probabilistic Neural Networks. *Computers & Industrial Engineering*, 63, 37-45.

- Khashei, M., Hejazi, S., & Bijari, M. (2008). A new hybrid artificial neural networks and fuzzy regression model for time series forecasting. *Fuzzy Sets and Systems*, 159, 769-786.
- Koutroumanidis, T., Ioannou, K., & Arabatzis, G. (2009). Predicting fuelwood prices in Greece with the use of ARIMA models, artificial neural networks and a hybrid ARIMA–ANN model. *Energy Policy*, 37, 3627–3634.
- Koutroumanidis, T., Ioannou, K., & Zafeiriou, E. (2011). Forecasting Bank Stock Market Prices With a Hybrid Method: The Case of Alpha Bank. *Journal of Business Economics and Management*, 12 (1), 144–163.
- Krenker, A., Bester, J., & Kos, A. (2011). Methodological Advances and Biomedical Applications. K. Suzuki (Ed.) içinde, *Introduction to the Artificial Neural Networks* (s. 3-19). Amerika Birleşik Devletleri : IntechOpen.
- Kurtoğlu, S. (2018). *Türkiye'nin 2018-2025 Dönemindeki Yumurta Üretiminin ARIMA Modeliyle Tahmini*. Yüksek Lisans Tezi. Erzurum: Atatürk Üniversitesi, Fen Bilimleri Enstitüsü .
- Latifoğlu, L., & Nuralan, K. (2020). Tekil Spektrum Analizi ve Uzun-Kısa Süreli Bellek Ağları ile Nehir Akım Tahmini. *Avrupa Bilim ve Teknoloji Dergisi, Özel Sayı* , 376-381.
- Lin, T., Guo, T., & Aberer, K. (2017). Hybrid Neural Networks for Learning the Trend in Time Series. *Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence*, (s. 2273-2279). Australia.
- Metin, İ., & Karasulu, B. (2019). İnsan Aktivitelerinin Sınıflandırılmasında Tekrarlayan Sinir Ağı Kullanan Derin Öğrenme Tabanlı Yaklaşım. *Veri Bilimi Dergisi*, 2 (2), 1-10.
- Neto, P., Ferreira, T., Lima, A., Vasconcelos, G., & Cavalcanti, G. (2017). A perturbative approach for enhancing the performance of time series forecasting. *Neural Networks*, 88, 114-124.
- Newbold, P. (1983). ARIMA Model Building and the Time Series Analysis Approach to Forecasting. *Journal of Forecasting*, 2, 23-35.

- Oliveira, J., & Ludermir, T. (2016). A Hybrid Evolutionary Decomposition System for Time. *Neurocomputing*, 180, 27-34.
- Öztemel, E. (2012). *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık .
- Öztürk, K., & Şahin, M. (2018). Yapay Sinir Ağları ve Yapay Zekâ'ya Genel Bir Bakış. *Takvim-i Vekayi*, 32.
- Pablo, B., Hilda, C., Xavier, A., Diego, J., Felipe, S., & Henry, B. (2016). Artificial Neural Network and Monte Carlo forecasting with generation of L-scenarios. *Intl IEEE Conferences on Ubiquitous Intelligence & Computing, Advanced and Trusted Computing, Scalable Computing and Communications, Cloud and Big Data Computing, Internet of People, and Smart World Congress* (s. 665-670). France: IEEE.
- Panch, T., Szolovits, P., & Atun, R. (2018). Artificial Intelligence, Machine Learning and Health Systems. *J Glob Health*, 8 (2), 1-8.
- Panigrahi, S., & Behera, H. (2017). A hybrid ETS–ANN model for time series forecasting. *Engineering Applications of Artificial Intelligence*, 66, 49-59.
- Papagera, A., Ioannou, K., Zaimes, G., Iakovoglou, V., & Simeonidou, M. (2014). Simulation and Prediction of Water Allocation Using Artificial Neural Networks and a Spatially Distributed Hydrological Model. *Agris on-line Papers in Economics and Informatics*, 6 (4), 101-111.
- Rhanoui, M., Yousfi, S., Mikram, M., & Merizak, H. (2019). Forecasting financial budget time series: ARIMA random walk vs LSTM neural network. *IAES International Journal of Artificial Intelligence*, 8 (4), 317-327.
- Rusănescu, M. (2014). ABC Analysis, Model For Classifying Inventory. *Magazine of Hydraulics, Pneumatics, Tribology, Ecology, Sensorics, Mechatronics*(2), 17-20.
- Saatçioğlu, D. (2016). *Aralıklı Talep Yapısına Sahip Ürünlerin Talep Tahmininde Makine Öğrenme Yöntemlerinin Uygulanması*. Doktora Tezi . İstanbul: İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü.
- Sagheer, A., & Kotb, M. (2019). Time series forecasting of petroleum production using deep LSTM recurrent networks. *Neurocomputing*, 323, 203-213.

- Slaughter, G. (2003). *Artificial Neural Network for Temporal Impedance Recognition of Neurotoxins*. Yayınlanmamış Yüksek Lisans Tezi . Amerika Birleşik Devleti : Virginia Common Wealth University, School of Engineering.
- Sol, H. (1983). *Processes and Tools for Decision Support*. New York: ELSEVIER SCIENCE PUBLISHING COMPANY.
- Su, H., Zio, E., Zhang, J., Xu, M., Li, X., & Zhang, Z. (2019). A hybrid hourly natural gas demand forecasting method based on the integration of wavelet transform and enhanced Deep-RNN model. *Energy*, 178, 585-597.
- Sugiartawan, P., Pulungan, R., & Sari, A. (2017). Prediction by a Hybrid of Wavelet Transform and Long-Short-Term-Memory Neural Network. *International Journal of Advanced Computer Science and Applications*, 8 (2), 326-332.
- Temür, A. (2019). *İşletmelerin Satış Bütçelerinin Oluşturulmasında ARIMA, LSTM ve Hibrit Modellerin Karşılaştırılması: Üretim İşletmesi Örneği*. Doktora Tezi . Sakarya: Sakarya Üniversitesi, İşletme Enstitüsü.
- Temür, A., Akgün, M., & Temür, G. (2019). Predicting Housing Sales in Turkey Using ARIMA, LSTM and Hybrid Models. *Journal of Business Economics and Management*, 20 (5), 920–938.
- Tok, K. (2017). *Hastalık Teşhisi İçin Bir Yapay Sinir Ağları Yazılımının Tasarlanması Ve Gerçekleştirilmesi*. Yüksek Lisans Tezi. Konya: Selçuk Üniversitesi, Fen Bilimleri Enstitüsü.
- Tortum, A., Gözcü, O., & Çodur, M. (2014). Türkiye'de Hava Ulaşım Talebinin ARIMA Modelleri İle Tahmin Edilmesi. *İğdır Üni. Fen Bilimleri Enst. Dergisi*, 4 (2), 39-54.
- Turban, E. (1988). *Decision Support and Expert Systems: Managerial Perspectives*. New York: Macmillan Pub Co.
- Wedding, D., & Cios, K. (1996). Time Series Forecasting by Combining RBF Networks, Certainty Factors, and the Box-Jenkins Model. *Neurocomputing*, 10, 149-168.

- Wongsatha, R., & Seedadan, I. (2016). A hybrid ARIMA and Neural Networks model for PM-10 pollution estimation: The case of Chiang Mai city moat area. *Procedia Computer Science*, 86, 273-276.
- Xu, W., Peng, H., Zeng, X., Zhou, F., Tian, X., & Peng, X. (2019). A hybrid modelling method for time series forecasting based on a linear regression model and deep learning. *Applied Intelligence*, 49, 3002–3015.
- Yavuz, S., & Deveci, M. (2012). İstatiksel Normalizasyon Tekniklerinin Yapay Sinir Ağın Performansına Etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*(40), 173.
- Yazıcıoğlu, N. (2010). *Yapay Zeka İle Talep Tahmini*. Yüksek Lisans Tezi. Bursa: Uludağ Üniversitesi, Fen Bilimleri Enstitüsü.
- Yıldırım, A. (2019). *Talep Tahmin Yöntemlerinin Karşılaştırmalı Analizi: Gıda Sektöründe Bir Uygulama*. Yüksek Lisans Tezi . İstanbul: İstanbul Kültür Üniversitesi, Lisansüstü Eğitim Enstitüsü.
- Yu, L., Jiao, C., Xin, H., Wang, Y., & Wang, K. (2018). Prediction on Housing Price Based on Deep Learning. *International Journal of Computer and Information Engineering*, 12 (2), 90-99.
- Yücesan, M. (2018). YSA, ARIMA ve ARIMAX Yöntemleriyle Satış Tahmini: Beyaz Eşya Sektöründe bir Uygulama. *İşletme Araştırmaları Dergisi*, 10 (1), 689-706.
- Zhang, G. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.
- Zhang, G., Patuwo, B., & Hu, M. (1998). Forecasting with artificial neural networks: The state of the art. *International Journal of Forecasting*, 14, 35-62.
- Zhu, B., & Wei, Y. (2013). Carbon Price Forecasting with a Novel Hybrid ARIMA and Least Squares Support Vector Machines Methodology. *Omega*, 41 (3), 517-524.

EK-1. UYGULAMADA KULLANILAN KÜTÜPHANELER

Django==3.0.3

django-bootstrap4==1.1.1

django-crispy-forms==1.9.0

django-matplotlib==0.1

django-tables2==2.3.1

et-xmlfile==1.0.1

Faker==4.0.3

Keras==2.2.5

Keras-Applications==1.0.8

Keras-Preprocessing==1.1.0

matplotlib==3.2.1

numpy==1.18.2

openpyxl==3.0.3

pandas==1.0.3

Pillow==7.1.1

pmdarima==1.6.0

scikit-learn==0.22.2.post1

scipy==1.4.1

tablib==1.1.0

tensorboard==1.14.0

tensorflow==1.14.0

urllib3==1.25.9

xlrd==1.2.0

ÖZGEÇMİŞ

ORCID NO: 0000-0003-0650-2231

Adı Soyadı : SETAR RİZVANCHE
Yabancı Dil : Türkçe, İngilizce
Doğum Yeri ve Yılı : Skopje Makedonya / 1993
E-posta : setarrizvanche@gmail.com

Eğitim ve Mesleki Geçmişi:

- 2020, Eskişehir Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği
- 2017, Kocaeli Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği