

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**MAKİNE ÖĞRENMESİ YARDIMIYLA ZİNCİR RESTORAN GIDA
SATIŞLARININ TAHMİN EDİLMESİ VE HAVA DURUMUNUN ETKİSİNİN
İNCELENMESİ**

YÜKSEK LİSANS TEZİ

Sezgi ŞENER

Endüstri Mühendisliği Anabilim Dalı

Mühendislik Yönetimi Programı

TEMMUZ 2019

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**MAKİNE ÖĞRENMESİ YARDIMIYLA ZİNCİR RESTURANT GIDA
SATIŞLARININ TAHMİN EDİLMESİ VE HAVA DURUMUNUN ETKİSİNİN
İNCELENMESİ**

YÜKSEK LİSANS TEZİ

**Sezgi ŞENER
507111231**

Endüstri Mühendisliği Anabilim Dalı

Mühendislik Yönetimi Programı

Tez Danışmanı: Doç. Dr. Başar ÖZTAYŞI

TEMMUZ 2019

İTÜ, Fen Bilimleri Enstitüsü'nün 507111231 numaralı Yüksek Lisans Öğrencisi Sezgi ŞENER, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı "MAKİNE ÖĞRENMESİ YARDIMIYLA ZİNCİR RESTURANT GIDA SATIŞLARININ TAHMİN EDİLMESİ VE HAVA DURUMUNUN ETKİSİNİN İNCELENMESİ"başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Doç. Dr. Başar ÖZTAYŞI**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Dr. Ömer Faruk Beyca**
İstanbul Teknik Üniversitesi

Prof. Dr. Selim Zaim
İstanbul Şehir Üniversitesi

Teslim Tarihi : 3 Mayıs 2019
Savunma Tarihi : 3 Temmuz 2019



ÖNSÖZ

Yardımlarından dolayı tez danışmanım Başar Öztaşı'ya teşekkür ederim.

Tezi yazarken bana desteklerini esirgemeyen eşime, ablama ve aileme ayrıca teşekkür ederim.

Mayıs 2019

Sezgi ŞENER
(Elektronik Mühendisi)





İÇİNDEKİLER

Sayfa

ÖNSÖZ	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
ÇİZELGE LİSTESİ.....	xiii
ŞEKİL LİSTESİ.....	xv
ÖZET	xvii
SUMMARY	xix
1. GİRİŞ	1
1.1 Türkiye’de Franchise Sektörü	2
1.2 Türkiye’de Gıda Sektörü	4
2. TALEP TAHMİNİ.....	7
2.1 Tahminin Önemi	7
2.1.1 Tahmin süreci ve yapılması gerekenler	7
2.2 Talep Tahmini	8
2.2.1 Talep tahmininde kullanılan yöntemler	8
2.2.2 Talep tahmininde kullanılan faktörler	9
3. LİTERATÜR.....	11
3.1 Literatürdeki Talep Ve Satış Tahminiyle İlgili Çalışmalar	11
3.2 Literatürde Hava Durmunun Satış Tahminine Etkisi İle İlgili Çalışmalar.....	16
3.3 Satış Tahmininde Literatürde Kullanılan Yöntemler Ve Faktörler.....	20
4. METODOLOJİ	31
4.1 Hata Fonksiyonları	31
4.1.1 Ortalama mutlak hata	31
4.1.2 Kök kareler karesi	32
4.2 Yöntemler.....	32
4.2.1 Basit ortalama ve medyan	34
4.2.2 Naive mevsimsel naive modelleri	34
4.2.3 Hareketli ortalama.....	35
4.2.4 Üstel düzleştirme yöntemleri	35
4.2.4.1 Basit üstel düzeltim yöntemi.....	35
4.2.4.2 Çift üstel düzeltim yöntemi.....	36
4.2.4.3 Üçlü üstel düzeltim yöntemi	38
4.2.5 Entegre (Karma) otoregresif hareketli ortalamalar	39
4.2.5.1 Otoresif modeller	39
4.2.5.2 Hareketli ortalama modelleri	39
4.2.5.3 Otoresif hareketli ortalama modelleri	40
4.2.6 Mevsimsel entegre otoregresif hareketli ortalama	41
4.2.7 Yapay sinir ağı (ANN).....	41
4.2.7.1 Katman sayısı	42
4.2.7.2 Öğrenme algoritması ve aktivasyon fonksiyonu.....	42
4.2.7.3 Dereceli alçalma.....	42
4.2.8 Derin sinir ağları	43

4.2.8.1 Çok katmanlı algılayıcı	43
4.2.8.2 Evrişimli sinir ağları	45
4.2.8.3 Tekrarlayan sinir ağları	48
4.2.8.4 Uzun kısa süreli bellek ağları	49
4.2.8.5 Derin sinir ağlarında kullanılan hiperparametreler	51
4.2.8.6 Derin sinir ağlarında görülen problemler	52
4.2.9 Makina öğrenmesi yöntemleri	53
4.2.9.1 Çoklu lineer regresyon modeli	53
4.2.9.2 Otomatik regresif elementlerle çoklu lineer regresyon modeli	53
5. UYGULAMA: BAYİLERİN GÜNLÜK SİMİT SATIŞLARININ TAHMİN EDİLMESİ	55
5.1 Problem Tanımı	55
5.2 Veri Seti Ve Modelin Belirlenmesi	55
5.3 Verinin Hazırlanması	57
5.3.1 Eksik verilerin bulunması	57
5.4 Veri Temizlenmesi	58
5.4.1 Eğitim ve test kümelerinin ayrılması	59
5.4.2 İleri doğrulama yöntemi ile tek ve çok adımlı tahmin modelleri	59
5.4.2.1 Tek adımlı tahmin	60
5.4.2.2 Çok adımlı tahmin	60
5.5 Kullanılan Yazılım	61
5.6 Yöntemlerin Veri Setine Uygulanması	61
5.6.1 Tek değişkenli/parametrelili analiz	62
5.6.1.1 Tek adım haftalık tahmin sonuçları	68
5.6.1.2 Zaman serisi analizi	70
5.6.1.3 Çok adım tahmin sonuçları	73
5.6.2 Çok değişkenli parametre analizi	74
5.6.2.1 Çok değişkenli sonuçlar	81
6. SONUÇ VE ÖNERİLER	83
KAYNAKLAR	85
EKLER	89
ÖZGEÇMİŞ	93

KISALTMALAR

AIC	: Akaike Information Criteria
ANN	: Artificial Neural Network
BP	: Backpropagation
RBF	: Radial Basis Function Network
LR	: Lineer Regresyon
ETS	: Exponential Smoothing
SES	: Simple Exponential Smoothing
NN	: Neural Networks - Sinir Ağları
NNAR	: Hibrit Neural Network Autoregressive Model
NNMA	: Hibrit Neural Network Moving Average Model
AR	: Otoregresif Model
MA	: Moving Average Model
ARIMA	: Autoregressive Integrated Moving Average
SARIMA	: Seasonal Autoregressive Integrated Moving Average
LASSO	: Least Absolute Shrinkage And Selection Operator
SVR	: Support Vector Regression
SVM	: Support Vector Machine
SAR	: Seasonal Autoregressive Model
ARDL	: Autoregressive Distributed-lagged model.
VAR	: Vector Autoregressive Model
KNN	: K Nearest Neighbours
LSTM	: Long short-term memory
RF	: Random Forest
AdaBoost	: Adaptive Boosting Model
MLR	: Multiple Lineer Regression
SEM	: Structural Equation Modeling
MAE	: Mean Absolute Error
MSE	: University of Minnesota
RMSE	: Root Mean Squared Error
MAPE	: Mean Absolute Percentage Error

MLP	: Multilayer Perceptron Model
CNN	: Convolution Neural Networks
RNN	: Recurrent Neural Network
CONV	: Convolution Layer – Evrişim Katmanı



ÇİZELGE LİSTESİ

Sayfa

Çizelge 1.1 : Ülkelere göre franchise marka sayıları.....	3
Çizelge 3.1 : Hava durumu faktörleri makaleler matrisi.	22
Çizelge 3.2 : İç faktörler makaleler matrisi.	23
Çizelge 3.3 : Dış faktörler makale matrisi.	24
Çizelge 3.4 : Yöntemler makaleler matrisi.	27
Çizelge 5.1 : Faktör listesi.	56
Çizelge 5.2 : ETS en iyi son üç sonuç.	63
Çizelge 5.3 : SARIMA En iyi son üç sonuç.	64
Çizelge 5.4 : Tek adım oniki haftalık tahmin modeli hata sonuçları.....	69
Çizelge 5.5 : Veri ile ilgili genel bilgiler	70
Çizelge 5.6 : ADF Değerleri.....	71
Çizelge 5.7 : Çok adımlı tek değişkenli tahmin sonuçları RMSE	73
Çizelge 5.8 : MAE çok adımlı tek değişkenli tahmin sonuçları	74
Çizelge 5.9 : Sürekli değişkenlerle satış rakamlarının korelasyon değerleri-1.	76
Çizelge 5.10 : Sürekli değişkenlerle satış rakamlarının korelasyon değerleri-2.	76
Çizelge 5.11 : Lag değerleri ile satış rakamlarının korelasyon değerleri.	78
Çizelge 5.12 : Hava durumu değerleri ile satış rakamlarının korelasyonu.	79
Çizelge 5.13 : Modelin tahmin yeterliliği.....	79
Çizelge 5.14 : Lineer model katsayıları.....	80
Çizelge 5.15 : Normalize edilmiş değerlerle modelin tekrar kurdulması gerekir.....	80
Çizelge 5.16 : Normalize olmuş değerlerle kurulan modelin R kare değerleri	81
Çizelge 5.17 : Çok değişkenli tahmin sonuçları.	82



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1 : 2012-2015 yılları gıda ve içecek sektörü istihdam verisi.....	5
Şekil 1.2 : Gıda perakende satışları mevcut ve tahmin edilen sektör büyüklüğü grafiği TGDF 2015 envanteri.....	5
Şekil 4.1 : Tekli yapay nöron; topalama fonksiyonu ve aktivasyon fonksiyonundan oluşur.	41
Şekil 4.2 : MLP örneği.	44
Şekil 4.3 : Soldaki ileri beslemeli sinir ağı, sağdaki 2 katmanlı 1x2 filtre büyüklüğü olan CNN örneği her nöron önceki katmandan iki giriş nöronundan beslenir ve ağırlıklar katmanlar arasında paylaşılır.....	45
Şekil 4.4 : Normal iki gizli katmanlı olan üç katmanlı bir sinir ağı.	45
Şekil 4.5 : Nöronları üç boyutta (genişlik, yükseklik, derinlik) CNN örneği modelin her katmanı 3D boyutlu girdiyi nöron aktivasyonlarının 3D boyutlu çıktısına dönüştürür.	46
Şekil 4.6 : Receptive alan görseli.	46
Şekil 4.7 : Girdi matrisi ve filtre matrisi.....	47
Şekil 4.8 : Girdi ve filtrenin çarpılması sonucu oluşan öznitelik haritası.....	47
Şekil 4.9 : RNN modelinin açık gösterimi.....	48
Şekil 4.10 : LSTM örneği.	49
Şekil 4.11 : Unutma kapısı.	49
Şekil 4.12 : Giriş kapısı.	50
Şekil 4.13 : Yeni hücre durumu.....	50
Şekil 4.14 : Çıkış Kapısı.	51
Şekil 4.15 : MLR-AR metodolojisi.	54
Şekil 5.1 : Kayıp değerlerin tahmin ettirilmesi.....	57
Şekil 5.2 : Kayıp verileri tahmin edildikten sonra veri analizi.	58
Şekil 5.3 : Tek adımlı zaman serilerinde çapraz doğrulama modeli.....	59
Şekil 5.4 : Zaman serisi yöntemlerinde kullanılan ileri doğrulama ve tek adımlı tahmin modeli.	60
Şekil 5.5 : Yapay sinir ağlarında supervised öğrenme modeline çevrilmiş ileri doğru tek adımlı tahmin modeli.	60
Şekil 5.6 : Zaman serisi yöntemlerinde kullanılan ileri doğrulama ve çok adımlı tahmin modeli.	60
Şekil 5.7 : Yapay sinir ağlarında supervised öğrenme modeline çevrilmiş ileri doğru çok adımlı tahmin modeli.	61
Şekil 5.8 : Haftalık toplam satış değerleri.	62
Şekil 5.9 : Oluşturduğumuz MLP model örneği girdi oniki çıktı bir.	65
Şekil 5.10 : Oluşturduğumuz CNN model örneği.	66
Şekil 5.11 : Oluşturduğumuz LSTM modeli örneği.	67
Şekil 5.12 : LSTM boxplot hata çizimi 52.676 RMSE (+/- 15.986).	68
Şekil 5.13: CNN boxplot hata çizimi 63.165 RMSE (+/- 1.421).	68
Şekil 5.14 : Tek adım tahminde yöntemlerin karşılaştırılması.	69

Şekil 5.15 : Tek adım tahminde yöntemlerin hata oranları.....	70
Şekil 5.16 : Otokorelasyon grafiği.	71
Şekil 5.17 : Veri setinin ACF/PACF grafikleri.....	72
Şekil 5.18 : Residual dağılımı.....	72
Şekil 5.19 : Residual(Hata) değerlerinin çizimi.....	73
Şekil 5.20 : Yöntemlerin karşılaştırması.....	74
Şekil 5.21 : İl bazında sıcaklık değerlerinin değişimi.....	75
Şekil 5.22 : İl bazında satış rakamlarının değişimi.....	76
Şekil 5.23 : Antalya aylara göre satış rakamları.	77
Şekil 5.24 : İstanbul aylara göre ortalama satış rakamları.	78
Şekil 5.25 : Ramazan ayındaki satışlarla diğer ayların kıyaslaması.	78
Şekil 5.26 : MLR ile yukarda belirlediğimiz değişkenlerle tahmin grafiği.	81
Şekil 5.27 : Çok değişkenli yöntemlerin hatalarının karşılaştırılması.	82



MAKİNE ÖĞRENMESİ YARDIMIYLA ZİNCİR RESTURANT GIDA SATIŞLARININ TAHMİN EDİLMESİ VE HAVA DURUMUNUN ETKİSİNİN İNCELENMESİ

ÖZET

Tüm işletmelerin gelecekteki sektörel konumlarını koruyabilmek ve geliştirmek için bir plan çerçevesinde uygun çözümler üretmeleri gerekir. Geleceğe dair plan yapmak için de gelecekteki olayları öngörebilmeleri gerekir. Bunun için de çeşitli veri ve teknikler kullanarak hem planlama yapar hem de olası problemlere karşı önceden önlem alınabilir. Bu amaçlarla kullanılan yöntemlerden bir tanesi de talep tahminidir.

Bu çalışmada; gıda sektöründe Zaman Serisi analiz yöntemleri, Lineer Regresyon, Derin Öğrenme yöntemleriyle tahmin modelleri kurulup bu modeller yardımıyla Türkiye'nin önde gelen simit mağazası zincirlerinden birinin simitsatışlarıyla hava durumunun ilişkisi incelenmiştir. Ayrıca modeller yardımıyla satış tahminleri yapılmıştır.

Çalışmada 2014 yılı Eylül ayından 2016 Haziran ayı arasında şube başı simit satışlarından, il içi sıcaklık, nem, basınç, yağış gibi hava durumu göstergelerinden ve Dolar/TL paritesinden, tatil günleri, ramazan gibi kategorik değişkenlerden yararlanılmıştır. Belirtilen makine öğrenmesi yöntemleri önce tek değişkenli sonrasında çok değişkenli olarak uygulanmış ve hata testleri yapılmıştır. Oluşturulan modellerin tahmin tutarlılığı ve genellenebilirliği incelenmiştir. Çalışma 6 bölümden oluşmaktadır. Birinci ve ikinci bölümde; zincir mağazaların sektörel bilgisi ve talep tahmini ile ilgili bilgiler verilmiştir. Üçüncü bölümde zaman serisi ve makine öğrenmesi yöntemlerinin hava durumu değişkenlerinin kullanıldığı literatür çalışmalarından bahsedilmiştir. Dördüncü bölümde makine öğrenmesi metodlarının en yaygın kullanılanları kısaca anlatılmış ve çağdaş metotlardan zaman serisi yöntemleri ve derin sinir ağları ayrıntılı olarak anlatılmıştır. Derin sinir ağlarından zaman serisi için kullanılan LSTM ağ yapısının yanı sıra CNN ve temel modellerden MLP ağları uygulanmıştır. Beşinci bölümde; öncelikle tek değişkenli tahmin yöntemiyle tek adım ve çok adımlı tahmin yapılmış ve yöntemler karşılaştırılmıştır. Bu tek değişkenli uygulama ile yeni derin öğrenme yöntemleri klasik yöntemlerle karşılaştırmak amaçlanmıştır. Sonrasında çok değişkenli yöntemle belirtilen hava durumu, önemli günler, mevsimsel değişkenler, lokasyon bilgileri kullanılarak lineer yöntemlerle önce değişkenlerin etkileri incelenmiş sonra da otoregresif modeller ve derin öğrenme modellerin tahmin tutarlılıkları karşılaştırılmıştır. Hangi değişkenlerin etkisinin daha çok olduğu gösterilmiştir. Çok değişkenli modellerin zaman serisi modellerine alternatif olabileceği gösterilmiştir. Bunların yanı sıra modellerin nasıl eğitildiği, nasıl test edildiği ve tahmin süreci hakkında detaylı bilgiler sunulmuştur. Altıncı bölümde ise çıkan sonuçlar yorumlanmıştır. Gelecekteki araştırmalarda kullanılabilecek faktörler ve yöntemler için öneriler sunulmuştur.



FORECASTING FOOD SALES ON CHAIN RESTAURANT AND INVESTIGATING WEATHER EFFECT ON SALES BY USING MACHINE LEARNING METHODS

SUMMARY

All businesses in need of decision-making must anticipate future events in order to maintain and improve their current status in the future and produce appropriate solutions within a good plan. The objective of prediction is to anticipate the future situations that may be encountered by businesses and to take precautions by using various data and techniques. This purpose is also envisaged in demand forecasting.

Sales forecasting is an important part of stock planning for wholesale and retail trade. It is a complex task because of the many factors affecting demand. The complexity of business dynamics often forces decision-makers to make decisions based on subjective mental models that reflect their experience. However, research shows that companies achieve better performance when applying data-based decision-making methods. In fact, companies in the top three of their sectors use data-based decision-making to become 5% more efficient and 6% more profitable than their competitors (Bohanec, Robnik-Šikonja 2017), (Wong, W. K., & Guo, Z. X., 2010). This encourages the business community to use data-driven decision models that enable more comprehensive and intelligent decision-making.

Timely and accurate sales forecasting in the food industry plays a key role in the profitability of operations. Retail food stocks consist of a wide range of perishable foods with short shelf life and different storage conditions, which complicates food sales forecasting (Doganis et al., 2006).

Analyzing sales data in stores helps improve store management, product management, and supply chain management, thereby reducing restaurant operating costs and improving food quality. At the institutional level, the creation of relevant information in restaurants greatly simplifies the strategic planning of companies. Thus, corporate governance can evaluate the impact of promotional activities on sales and brand recognition, evaluate business trends, analyze price elasticity, and measure brand loyalty. Therefore, accurate and timely sales forecasts enable us to conduct studies from many different perspectives and are critical in this respect (Lasek and Saunders, 2016).

Historically, restaurant managers use either recent history data or simple logical methods to estimate customer numbers or sales volume. These techniques consist of an intuitive prediction, often based on the experience of the manager. However, restaurant sales forecasts, time, weather conditions, economic factors, random cases and so on. It is a complex task because it is influenced by many factors that can be classified as. In this case, old techniques may give incorrect results (Lasek and Saunders, 2016).

The aim of this study is to compare the estimation of simit sales, which is one of the most consumed daily snacks in Turkey, the accuracy of the learning methods and determine the model that provides the highest accuracy and the factors affecting the buying behavior of one of the leading simit chain stores in Turkey in the food sector by using Time Series Analysis methods,.

Between January 2014 and July 2016, the study benefited from the sales of simit per branch, weather conditions such as temperature, humidity, pressure, precipitation and district population values in the province. It is observed that reliability and consistency of the model predictions by the post-implementation error tests. The study consists of six main parts. In the first and second chapter, sectoral information and demand forecasting of chain stores are given.

Demand forecasting plays an important role in the activities of each organization in which customer or consumer demand exists, particularly in the services, manufacturing, and sectors as part of the actual supply chain. Demand forecasting; is the process of calculating the future demand for a product or service with an acceptable margin of error.

In the literature, there is a wide range of demand forecasting studies conducted in different sectors on a general and store basis (Donkor et al., 2012), (Witt, 1995), (Suganthive Samuel, 2012), (Fildes and Kumar, 2002), (Nenni and Pirolo, 2013).

Analyzing store sales data helps improve store-based operations management, product management, supply chain management, and thus reduces restaurant operating costs; improves the quality of service and foods. At the corporate level, extracting relevant information in restaurants greatly simplifies the company's strategic planning. Thus, corporate governance can evaluate the impact of promotional activities on sales and brand recognition and business trends. Price elasticity analysis. It also measures brand loyalty. For this reason, accurate and timely sales forecasts enable us to carry out studies from many different perspectives and are critical in this respect (Lasek, Cercone and Saunders, 2016).

The methods used in the literature for Demand Forecasting can be grouped under three main headings. The first is time series methods and the second is deep learning methods and other machine learning methods. Time series methods generally focus on modeling patterns within a single data set. They are mostly used in the prediction of linear models. Machine learning methods estimate demand data using supervised and unsupervised learning methods of different factors. They can predict both linear and nonlinear relationships. Deep learning learning methods can be predicted by simple neural network logic for both time series and multivariate models. The results of time series methods can be interpreted more easily. Machine learning and deep learning methods are also called black box models because they are difficult to interpret (Bohanec et al., 2017).

In literature studies on sales and demand estimation, many factors affecting customer demand are examined. These factors have been classified as internal and external factors in some studies (Obliobaité et al. 2012), (Ramanathan and Muyltermans, 2010). Accordingly, the variables used in the literature can be grouped as internal and external factors. Weather effects as external factors (humidity, precipitation, snowfall, storm), Holidays, Great events, Macroeconomic effects, Competition, Social media data; internal effects are classified according to the main headings such as calendar effect (days of the week, days of the month, months of the year, weeks of the year), historical data (lag), product characteristics, promotion, store characteristics.

In the third chapter, previous studies about sales forecasting and forecasting methods are described. In the fourth chapter, machine learning, time series methods and deep neural networks methods are explained in detail from contemporary methods. In the fifth chapter; one-step and multi-step estimations were made and the methods were compared with the one-variable estimation method. Afterwards, the effects of variables were examined by linear methods using the weather conditions, important days, seasonal variables, location information and then the predictive consistency of the autoregressive models and deep learning models. In the sixth chapter, the results are interpreted and proposals for future research are presented.

When determining the data set, firstly the needs of the company were taken into consideration. The company wants sales and orders to be estimated. We have order data from the wholesale center. Store order data is available, but store sales data is not available. When analyzed, stores can calculate their daily orders based on the daily increased products because they buy frozen food. Therefore, the variability in daily orders does not clearly reflect sales expectations. It is considered appropriate to use weekly sales values in order to make less difference in daily orders and sales numbers. As a result, the total number of orders per week was taken as a reference and it was decided to make a weekly estimate.

Both univariate and multivariate analyzes will be performed to compare the performance of the methods according to different needs. First, time series methods will be applied to a univariate data set. Secondly, a multi-parameter time series estimate will be made. In addition, the effect of other variables/factors on the estimation variable will be examined.

For the multivariate model, the factors affecting demand in the light of literature studies and ideas received from store authorities were classified as in the table below.

These are grouped under four main headings:

- Important days; National Holidays, School Holiday, Ramadan
- Macro Variables; USD / TRY,
- Seasonal Variables; Week, Month, Year
- Store Traffic; Province

In brief, results show, classical methods can give good results in time series. However, although the LSTM method has been proposed in time series, one-dimensional CNN has also shown good results. In addition, hybrid deep neural network models proved to be effective in multi-step estimation. In the one-step estimation, it was observed that the CNN method was as good as the LSTM method.

In multiple linear analysis, firstly correlation and linear model analysis were used to investigate the effect of variables on sales values. Temperature values do not show the same effect in all provinces. Istanbul has the highest correlation with temperature values and sales figures with -0.6. In the linear model analysis, a descriptive model was created by using the temperature, sunshine time, humidity, snowfall, dollar parity and the sales value 4 weeks ago.

The month of Ramadan , temperature and sales value 4 weeks ago statistically significant $p < 0.001$, snowfall representing extreme weather conditions was statistically significant $p < 0.05$. After multiple linear analysis, sales estimation was

made with multivariate models. According to these estimates, the best result was MLR with 39 RMSE values.

In future studies, if store traffic and store sales information is available, these variables can be envisaged to form richer and explanatory models. The presence of store sales data could have been possible to determine the effect of temperature on store traffic and human behavior. In addition, the effect of promotions on sales could be measured with promotional information. In subsequent studies, the effect of air temperature on other products or, if sufficient data are available, can be examined in terms of the human choice of intake.



1. GİRİŞ

Satış tahmini, toptan ve perakende ticaret için stok planlamanın önemli bir parçasıdır. Talebi etkileyen çok sayıda faktörden dolayı karmaşık bir görevdir. İş dinamiklerinin karmaşıklığı karar vericileri genellikle, deneyimlerini yansıtan subjektif zihinsel modellere dayalı kararlar vermeye zorlamaktadır. Bununla birlikte, araştırmalar, şirketlerin veri temelli karar alma yöntemlerini uyguladıklarında daha iyi performans elde ettiğini göstermektedir. Hatta sektörlerinin ilk üçündeki şirketler veriye dayalı karar verme kullanarak, rakiplerinden ortalama %5 daha verimli ve %6 daha karlı olmaktadır (Bohanec, Robnik-Šikonja 2017), (Wong, W. K., & Guo, Z. X.,2010). Bu durum, iş çevrelerini daha kapsamlı ve akıllı karar vermeyi sağlayan, veri temelli karar modelleri kullanmaya teşvik etmektedir.

Gıda endüstrisinde zamanında ve doğru satış tahmini yapmak operasyon karlılığında temel rol oynar. Perakende gıda stokları, kısa raf ömrüne ve farklı depolama koşullarına sahip çok çeşitli bozulabilir gıdalardan oluşmakta ve bu da gıda satış tahmini karmaşık hale getirmektedir (Doganis ve diğerleri, 2006).

Mağazalardaki satış verisini analiz etmek mağaza bazında operasyon yönetimi, ürün yönetimi, tedarik zinciri yönetimini geliştirmeye yardımcı olmakta ve dolayısıyla restoran işletme giderlerini düşürürken gıdaların kalitesini artırmaktadır. Kurumsal düzeyde ise, restoranlarda ilgili bilgilerin oluşturulması, şirketlerin stratejik planlamasını büyük ölçüde kolaylaştırmaktadır. Böylece kurumsal yönetim, promosyon faaliyetlerinin satış ve marka tanıma üzerindeki etkisini değerlendirilmekte, iş trendlerini değerlendirebilmekte, fiyat esneklik analizini yapılabilen ve marka sadakatini ölçebilmektedir. Bu nedenle, doğru ve zamanında satış tahminleri, birçok farklı perspektifte çalışmalar yapılmasına olanak sağlar ve bu açıdan da kritiktir (Lasek ve Saunders, 2016).

Tarihsel olarak, restoran yöneticileri müşteri sayılarını ya da satış miktarını tahmin etmek için ya yakın geçmiş verilerini ya da basit mantıksal yöntemleri kullanmaktadır. Bu teknikler, genellikle yöneticinin deneyimlerine dayanan sezgisel bir tahminden oluşmaktadır. Ancak, restoran satış tahminleri, zaman, hava koşulları, ekonomik

faktörler, rastgele vakalar vb. olarak sınıflandırılabilir çok sayıda faktörün etkisinde kaldığı için karmaşık bir görevdir. Bu durumda eski teknikler hatalı sonuç verebilir (Lasek ve Saunders, 2016).

Geçmiş yıllarda tahmin alanında birçok yeni teknik bulunmuştur ve farklı sektörlerde talep ve satış tahmini yapmak için uygulanmıştır. Tahmin yöntemleri hareketli ortalama gibi basit yöntemlerden derin öğrenme ve gelişmiş makine öğrenme sistemlerine evrilmiştir (Wong veGuo 2010; Aksoy ve arkadaşları 2014; Wu ve arkadaşları 2017; Xiong ve arkadaşları, 2018; Liu ve arkadaşları 2018; Långkvist ve arkadaşları 2014; Shabani ve arkadaşları,2017). Bu konuda Doganis ve arkadaşları gıda sektöründe kısa süreli raf ömrü olan ürünlerle ilgili yapay sinir ağları kullanarak tahmin çalışması yapılmıştır. Bunun yanı sıra çeşitli sektörlerde mağaza satışlarını etkileyen faktörler incelenmiştir (Arunraj ve Ahrens, D. 2015, Ramanathan ve Muyldermans, 2010 ; Žliobaitė ve arkadaşları, 2012; Liu ve Ichise, 2017).

1.1 Türkiye’de Franchise Sektörü

Türkiye, franchising’e şehirlerarası yolcu taşımacılığı ile 1960’lı yıllarda başlamıştır. Günümüzde, Türk franchising uygulamaları, cilt bakım ürünleri, hazır giyim, fast food, temizlik, araba kiralama, çikolata, ofis kırtasiye ürünleri, emlak, yayıncılık, iletişim, müzik marketleri, kargo, Do-it-yourself mağazalar, kozmetik ve otomotiv ürünleri gibi çeşitli sektörlerde yaygın olarak görülmektedir. Franchising, Türkiye’de oldukça yeni bir iş anlayışı olmasına rağmen, çok hızlı büyümektedir.

Türkiye’de restoran pazarında, markalı kafeler, fast food, hazır giyim, spor merkezleri gibi birçok alanda, insanların kazançlarının ve çalışma saatlerinin artması dolayısıyla birçok hizmeti dışardan almaya başlasıyla toplumdaki dışarda yeme alışkanlıklarının değişmesi, insanların sosyalleşme davranışlarının değişmesi, yeni alışveriş merkezlerinin açılması, konut piyasasının gelişmesi, gelir düzeyinin artmasıyla beraber birçok alanda tüketimin artmasına neden olmuştur. Bu da yeni franchise sektörlerinin oluşmasına dolayısıyla franchise sayısını artırarak yeni sektörlerin yaygınlaşmasını sağlamıştır.

Zincirlerin sektörel dağılımlarına bakıldığında, gıda sektörünün %24, ticari malların %27, hizmetlerin %16 ve giyim sektörünün %33 payı olduğu görülmektedir. Market, yetişkin giyim ve aksesuar zincirlerinin sayısı 200’den fazladır. Kafe, fast-food ve

restoran zincirlerinin sayısı ise 100'ü aşmış durumdadır. Alışveriş merkezlerinin hızlı yayılmasının da etkisiyle, Türkiye'de bir franchise markalaşması hızlanmaktadır. Avrupa Franchise Federasyonu (EFF) istatistiklerine göre Türkiye franchise zinciri sayısında Avrupa birincisidir. Türkiye'yi 1375 markayla Fransa, 960 markayla Almanya izlemektedir. Dünyanın en güvenli yaygınlaşma modeli olan franchising hemen hemen her sektörün ilgisini çekmektedir. UFRAD (Uluslararası Franchising Derneği) verilerine göre, Türkiye'de yaklaşık 1876 zincir mağaza bulunmaktadır. Bunların %24'ü yabancı, %74'ü Türk kökenli markalardır. Bunlara ait 50 bin civarında şube franchise ya da bayılık sistemiyle büyümektedir. Türkiye'de franchise veren 1471 şirket bulunmaktadır. Bu şirketlerin zincirler içindeki oranı ise %78'dir. Sadece kendi şubelerini açıp kendileri işleten zincirler %22 oranındadır (<https://www.becomeafranchise.com/turkiyede-franchising-pazari/>).

Çizelge 1.1 : Ülkelere göre franchise marka sayıları.

Ülke	Franchise marka sayısı							
Avrupa	2007	2008	2009	2010	2011	2012	2013	2014 Est.
AT-Austria	390	411	435	420	440	445		445
BE-Belgium	200	240	320	360	350			350
HR-Croatia	120	145	150	168	175	180	180	180
CZ-Czech Rep	131	137		150	168	200	219	219
DK-Denmark	180	185	188	188	188			188
FI-Finland	220	255	265	270	270	275	277	294
FR-France	1.137	1.229	1.369	1.477	1.569	1.658	1.719	1.796
DE-Germany	910	950	960	980	990			990
EL-Greece	544	560	563	450	456			456
HU-Hungary	330	350	350	361	361			361
IT-Italy	847	852	869	883	878	938	939	939
NL-Netherlands	676	687	692	714	739	769		769
PL-Poland	402	512	618	739	805	864	930	930
PT-Portugal	501	521	524	570	578			578
SK-Slovakia					80			80
SI-Slovenia	103	106	107	103	106	108		108
ES-Spain	850	875	919	934	947			1.199
SE-Sweden	350	400	550	640	700			700
CH-Switzerland			275	275	275			275
TR-Turkey				1.669	1.708	1.860	1.840	1.840
UK	809	838	845	900	929		930	930
TOTAL				12.251	12.712			13.627

Türkiye'deki toplam franchise sayısı Çizelge 1.1'e göre 2009 yılından sonra hızlı artış göstermiştir. Ön tahminler, Türkiye'nin franchise pazarının hacminin 43 milyar ABD Doları'nı aştığını ve önümüzdeki yıllarda 50 milyar ABD Doları'na ulaşacağını göstermektedir.

Türkiye'deki yabancı bayilikler arasında McDonald's, Domino's Pizza, Burger King, Metro ve Caffè Nero gibi global markalar bulunmaktadır. Bunun dışında Simit Sarayı (gıda), Koton (giyim) ve İstikbal (mobilya) gibi büyük markalar da ana iş modeli olarak franchising kullanmaktadır.

Bu çalışmada verileri kullanılan firmanın yurt içinde 234 mağazası, şirketin yurtdışındakilerle beraber ise 367 mağazası vardır. Firma, büyüme planı çerçevesinde 2020 yılına kadar yurtdışında pek çok ülkede mağazalaşmayı hedeflemektedir. İngiltere'de 200'ün üzerinde, Amerika, Almanya, İngiltere, Hollanda, Belçika, İsveç, Rusya, Polonya, Azerbaycan, Irak, Kuveyt, Nahcivan'da toplam 600'ün üzerinde mağaza açılması hedeflenmektedir (Çizelge 1.1).

1.2 Türkiye'de Gıda Sektörü


Gıda ve içecek sektörü, milli gelir ve istihdama olan katkısına ek olarak, toplumun sağlığı, gıda güvenliği, çevre kirliliği ve tarımsal hammaddelerin maliyeti açısından da stratejik bir öneme sahiptir. Özellikle tarım ve turizm sektörleriyle önemli bir arz-talep ilişkisi vardır. Türkiye gibi orta sınıfın zenginleştiği gelişmekte olan bir ülkede, gıda tüketim alışkanlıklarındaki değişiklikler, bu sektörün dinamiklerini etkileyen önemli bir unsur olarak karşımıza çıkmaktadır.

TÜİK verilerine göre, gıda ve içecek sektörü 2015 yılında gayrisafi yurt içi hasıla (GSYİH) artışına paralel olarak %11,7 oranında büyümüştür (Şekil 1.2). Türkiye'de 42 binin üzerinde gıda ve içecek işletmesi bulunmakta, sektör toplam imalat sanayii şirketlerinin içinde yüzde %10-12'lik bir paya sahiptir. İmalat sanayii istihdamında da yaklaşık %10-13'lük bir paya sahiptir. Gıda ve içecek sektörü, Türkiye'ye gelen doğrudan yabancı yatırım tutarında da önemli bir paya sahiptir. Sektör 2016 yılında yaklaşık 5,1 milyar dolarlık net ihracat yapmıştır. Ancak, sektörün imalat sanayii toplam Ar-Ge yatırımları içindeki düşük payı (%2,3) ve %60-70 düzeyinde seyreden düşük kapasite kullanım oranı, rekabet gücü bakımından sorunlara işaret etmektedir (Şekil 1.1).

SEKTÖR	2011		2012		2013		2014		2015	
	İşyeri	İstihdam	İşyeri	İstihdam	İşyeri	İstihdam	İşyeri	İstihdam	İşyeri	İstihdam
Gıda	39.100	397.679	40.233	440.930	41.285	457.370	42.030	470.390	42.021	469.126
İçecek	482	13.756	484	14.304	509	15.035	530	15.957	499	16.214

Kaynak: TÜİK

Şekil 1.1 : 2012-2015 yılları gıda ve içecek sektörü istihdam verisi.



Şekil 1.2 : Gıda perakende satışları mevcut ve tahmin edilen sektör büyüklüğü grafiği TGDF 2015 envanteri.



2. TALEP TAHMİNİ

2.1 Tahminin Önemi

Tahmin, akla, sezgiye ya da birtakım verilere dayanarak, gelecekteki bir olayı, bir durumu bilmek, kestirmek demektir. Genel olarak, geçmiş eğilimlere, geçmiş verilere ve öngörülen gelecekteki parametrelere verilen hususlara dikkat edilerek bir şeylerin tahmin edilmesi süreci olarak anlaşılmaktadır. İşletmeler sadece finansal konular için değil hemen hemen her iş kararı gelecekle ilgilidir ve bu nedenle tahminlere dayanmaktadır. Her plan, sonuçta, bir tahmine ihtiyaç duymaktadır (Kolassa ve Siemens, 2016). Hızlı değişen teknolojik koşulları ve mikro ve makro etkilerin artmasıyla belirsizliği azaltmak için yüksek tahmin doğruluğu olan, hızlı yöntemlere ihtiyaç duyulmaktadır. Bu nedenle veriye dayalı tahmin yöntemler önem kazanmıştır (Lasek ve Saunders, 2016).

2.1.1 Tahmin süreci ve yapılması gerekenler

Tahmin süreci modele ve veriye bağımlı bir süreçtir ve istatistiksel yöntemlere dayanmaktadır. Bu nedenle her zaman bir hata payı içermektedir. Bu hataya tahmin hatası denir. Tahmin birçok faktörün bir matematiksel denklemi olarak düşünülebilir. Tahmin modelleri her zaman tahmin değişkenini etkileyen faktörlerin tümünü içermemektedir. Modeli kurarken öngörülemeyen ya da veri setine ulaşamayan faktörler olmaktadır. Bu nedenle elde edilen modelin tahmin değişkenini ne kadar iyi modelleyebildiğini bilmek gerekmektedir. Bu duruma bağlı modelin başarı aralığı ve tahminin başarı aralığı da bilinmelidir. Bir seri için oluşturulan tahmin modeli her değişkende aynı sonucu vermemektedir. Ayrıca tahminleri yorumlarken veri setinin güvenilirliği geneli ne kadar doğru örneklediği ve örneklemin büyüklüğü de çok önemlidir.

Tahmin yapılırken öncelikle tahminin amacının belirlenmesi gerekmektedir. Sonrasında tahmin süresine karar verilmelidir. Tahmin süresinin kısa ya da uzun olmasına göre tahmin başarısı değişebilmektedir. Bu nedenle tahmin süresine karar vermek önemlidir. Ardından toplanan tahmin yapılacak veri ile modelin

oluşturulmaktadır. Sonrasında modelin geçerliliği test edilmektedir. Tahmin modelinin başarısına göre model test kümesine uygulanmaktadır.

Tahmin modelinin geçerli olmaması durumunda bu modelin sonucu planlamada kullanılmamalıdır. Model, toplanan veri seti ya da yöntemler değiştirilerek tekrar test edilmelidir. Test setinin ve modelin hatası ölçülürken bilinen kare ortamların karekökü gibi hata fonksiyonları kullanılmaktadır.

Tahmin süreci ve modelinin kurulması, veri, model, ihtiyaç duyulan doğruluk derecesi, veri setini etkileyen faktörlere, bu faktörlerin verisinin elde edilmesine ve kurulan modelin hesaplanabilirliğine bağlıdır.

2.2 Talep Tahmini

Talep tahmini, gerçek tedarik zincirinin bir parçası olarak hizmet, imalat, sektörleri başta olmak üzere müşteri ya da tüketici talebinin var olduğu her bir organizasyonun faaliyetlerinde önemli rol oynar. Talep tahmini; bir ürün veya hizmetin için gelecekte oluşacak olan talebin, kabul edilebilir bir hata payıyla hesaplanması işlemidir.

Literatürde farklı sektörlerde hem genel hem mağaza bazında yapılmış çok çeşitli talep tahmin çalışmaları vardır (Donkor ve arkadaşları, 2012), (Witt,1995), (Suganthive Samuel, 2012), (Fildes ve Kumar, 2002), (Nenni ve Pirolo, 2013).

Mağazalardaki satış verisini analiz etmek mağaza bazında operasyon yönetimi, ürün yönetimi, tedarik zinciri yönetimini geliştirmeye yardımcı olur ve dolayısıyla restoran işletme giderlerini düşürmekte; hizmet ve gıdaların kalitesini artırmaktadır. Kurumsal düzeyde ise, restoranlarda ilgili bilgilerin çıkarılması, şirket stratejik planlamasını büyük ölçüde kolaylaştırmaktadır. Böylece kurumsal yönetim, promosyon faaliyetlerinin satış ve marka tanıma üzerindeki etkisini ve iş trendlerini değerlendirebilmektedir. Fiyat esneklik analizini yapabilmektedir. Ayrıca marka sadakatini ölçebilmektedir. Bu nedenle, doğru ve zamanında satış tahminleri, birçok farklı perspektifte çalışmalar yapılmasına olanak sağlar ve bu açıdan da kritiktir (Lasek, Cercone ve Saunders, 2016).

2.2.1 Talep tahmininde kullanılan yöntemler

Talep Tahmini için literatürde kullanılan yöntemleri üç ana başlıkta toplanabilir. Birincisi zaman serisi yöntemleri, ikincisi makine öğrenmesi yöntemleri üçüncüsü

derin öğrenme yöntemleridir. Zaman serisi yöntemleri genelde tek veri setinin içindeki desen'i modellemeye odaklanmaktadır. Daha çok lineer modellerin tahmininde kullanılmaktadırlar. Makine öğrenmesi yöntemleri farklı faktörlerin denetimli ve denetimsiz öğrenme yöntemlerini kullanarak talep tahmini istenen veriyi tahmin etmektedir. Hem lineer hem lineer olmayan ilişkileri tahmin edebilmektedirler. Derin öğrenme öğrenme yöntemleri hem zaman serileri için hem de çok değişkenli modeller için basit sinir ağı mantığıyla tahmin yapabilmektedir. Zaman serisi yöntemlerinin sonuçları daha kolay yorumlanabilmektedir. Makine öğrenmesine ve derin öğrenme yöntemlerine yorumlanabilirliği zor olduğu içi kara kutu modelleri de denmektedir (Bohanec ve arkadaşları, 2017).

2.2.2 Talep tahmininde kullanılan faktörler

Genel olarak, talebi etkileyen faktörler müşteri davranışlarını yansıtmaktadır. Satış ve talep tahmini ile ilgili literatür çalışmalarında müşterinin talebini etkileyen çok sayıda faktör incelenmiştir. Bu faktörler kimi çalışmalarda iç ve dış faktörler olarak sınıflandırılmıştır (Žliobaitė ve arkadaşları 2012), (Ramanathan ve Muyltermans, 2010). Buna göre literatürde kullanılan değişkenleri iç ve dış etkenler olarak gruplanabilir. Dış etkenler olarak hava durumu etkisi (nem, yağış, kar yağışı, fırtına), Tatil günleri, Büyük etkinlikler, Makroekonomik etkiler, Rekabet, Sosyal medya verileri; iç etkiler olarak takvimsel etki (haftanın günleri, ayın günleri, yılın ayları, yılın haftaları), geçmiş veriler(lag), ürün karakteristiği, promosyon, mağaza karakteristiği gibi ana başlıklara göre sınıflandırılmıştır. Bazı makalelerde ise kişilerin satın alma davranışları da modele dahil edilerek kişilerin satın alma psikolojisine etkileyen faktörler de incelenmiştir. Tüketicinin demografik özellikleri, Satın Alma sıklığı gibi bilgiler modele dahil edilmiştir. Ayrıca sadece satış değerleri değil mağaza trafiği de satış tahminini etkileyen bir faktör olarak değerlendirilmektedir. Bu nedenle mağaza trafiği satış adedi ilişkisi de incelenmektedir (Lasekve arkadaşları, 2016).

Hava durumu etkisi, literatürde hava durumunun üç belirgin etkisinden bahsedilmektedir. Birincisi satın alınacak ürüne etkisi, ikincisi mağaza trafiğine etkisi, üçüncüsü de gecikme etkisidir. Mağaza trafiğine etki ekstrem hava koşulları kaynaklı olabilir. Genel olarak, havanın müşterilerin satın alma davranışı üzerindeki olumsuz etkisi satın alma zamanında gecikmelere sebep olur. Bu tür hava durumu etkileri gecikmiş satın almalara neden olabilir. Gıda perakende mağazalarında, müşterilerin

kötü hava koşulları nedeniyle beklemesi veya ertelenmesi eğilimi yoktur. Kötü hava koşullarının gıda sektöründe genellikle mağaza trafiğinde düşüş yaratması beklenmektedir (Arunraj ve Ahrens, 2016).

Sezonsal hava durumunun daha önceki çalışmalarda direk mağaza trafiğini etkilediği düşünülmektedir. Özetle gıda ile ilgili hava durumu etkisini hava etkili mod ve hava trafiğine etki olarak 2 ana gruba ayrılabilir. Burada ekstrem hava durumu ve normal sezonsal hava durumu etkisi incelenebilir. Bu etkiler bölgesel olarak farklılık gösterebilmektedir. Tropik bölgelerde nem belirgin şekilde psikolojik etkilere sahiptir. Çok kar yağan bölgelerde kar yağışları ekstrem hava koşulları olarak değerlendirilmemektedir. Bu nedenle hava durumu değişkenlerinin modeli buna uygun yapılmalıdır. Literatürde kullanılan değerler ortalama sıcaklık, nem, basınç, rüzgâr, güneşlenme süresi, kar, fırtına, kasırgadır (Arunraj ve Ahrens, 2016).

Önemli günler etkisi; ramazan ayı ve bayramlarda satışlarda ciddi düşüşler yaşanmaktadır. Bu durum mağaza trafiğini birinci dereceden etkiler. Okulların tatil olduğu günlerde (tatil günleri, festival günleri, okul tatilleri) de yerel yükselmeler gözlemlenebilir. Ürün Karakteristiği ; Günümüzde var olan güçlü rekabet nedeniyle, çoğu üretim kuruluşu karlarını artırmak ve maliyetlerini azaltmak için sürekli bir çaba göstermektedir. Doğru satış tahmini, yukarıda belirtilen hedefleri karşılamının kullanışlı bir yoludur, çünkü bu, müşteri hizmetlerinin iyileştirilmesine, kayıp satış ve ürün iadelerinin azaltılmasına ve daha verimli üretim planlamasına yol açar. Ürün satışları hava durumunda genel olarak iki şekilde etkilenir. Birincisi etkisi mağaza trafiği yoluyla, ikincisi ise kişinin satın aldığı ürünün çeşidinin değişmesi şeklinde gerçekleşebilir. Ürün karakteristiğini etkileyen faktörler: tazelik, görüntü, kalite, raf ömrü (Bertrand, Brusset ve Fortin, 2015), (Tian ve arkadaşları, 2018), (Bozkir ve Sezer, 2011). Promosyon ; Promosyonların etkisi mağaza trafiğinden çok satışlardaki artışa yönelik olabilir. Bir tane simit alınacakken simit artı çay satışı yapılmasını sağlayabilir. Bu da satın almayı artırabilir. İlgili faktörler şu şekilde sıralanabilir: promosyon, promosyon süresi, promosyon miktarı, indirim, mağaza Karakteristiği, makroekonomik değişkenler, rekabet, sosyal medya verileri, takvimsel etkiler, geçmiş veriler olarak sınıflandırılabilir (Arunraj ve Ahrens, 2015) , (Arunraj ve Ahrens, 2016), (Ramanathan ve Muyldermans, 2010), (Tian ve Zhang, 2018).

3. LİTERATÜR

Satış tahmini ile ilgili çalışmalar, müşterilerin ihtiyaçlarına hızla cevap verebilmek ve kaynakları en etkin şekilde kullanabilmek için birçok firmanın sıklıkla kullandığı yöntemler arasında yer almaktadır. Özellikle gıda endüstrisi için, birçok gıda ürününün kısa raf ömrü ve ürün kalitesinin insan sağlığıyla olan ilişkisi nedeniyle başarılı satış tahmin sistemleri çok faydalı olmaktadır (Doganis ve diğerleri, 2006). Literatürde satış ve talep tahminiyle ilgili çok sayıda farklı yöntemle çalışma yapılmıştır. Ayrıca bunun yanında hava durumunun ve diğer iç ve dış faktörlerin etkisiyle ilgili de çalışmalar yapılmıştır. Bu çalışmalara aşağıdaki bölümlerde yer verilmiştir.

3.1 Literatürdeki Talep Ve Satış Tahminiyle İlgili Çalışmalar

Bohanec ve arkadaşları (2017) makine öğrenme modellerinin satış tahmininde kullanılması ile ilgili çalışmasında son zamanlarda, son model kara kutu tahmin modellerinin açıklanmasını destekleyen yeni bir genel açıklama metodolojisi önerilmiştir. Sonuçlar, metodolojinin birçok modelde etkin kullanılabilirliğini göstermektedir. Yaklaşımın bu esnekliği ve takip edilmesi kolay açıklamaları birçok farklı uygulama için uygundur. Kara kutu modelleri daha iyi tahmin performans göstermelerine rağmen açıklanabilirliğin düşük olmasından ve değişkenlerin bağımlılıklarının, değişken önemlilik ölçümlerine etkisinden dolayı uygulamalarda tercih edilmediği görülmektedir. Bu yaklaşımla kara kutu modellerinin insan etkileşimi ve analizi için erişilebilirliğini ve uygulanabilirliğini artırmak amaçlanmıştır. Makine öğrenimi model seçiminin model açıklamadan ayrılması, uzman ve akıllı sistemler için önemli bir avantajdır. Belirli bir tahmin modeline bağlı olmayan açıklamalar, kolay değerlendirmeler ve anahtarlama yoluyla iş ortamında yeni ve karmaşık modellerin kabul edilmesinin olumlu yönde etkilemesi amaçlanmıştır.

Doganis ve diğerleri 2006 yılındaki çalışmalarında, doğrusal olmayan zaman serisi satış tahmin modellerini geliştirmek için yeni bir yöntem uygulanmıştır. Bu yöntem iki yapay zekâ teknolojisinin, yani radyal temel fonksiyonu (RBF) sinir ağı mimarisi

ve özel olarak tasarlanmış bir genetik algoritmanın (GA) birleşimidir. Metodolojide, büyük bir süt ürünleri imalat şirketi tarafından sağlanan taze süt satış verileri kullanılmıştır. Linear AR, Holt Winters, LinearAR-NNMA, Linear AR-Linear MA, NN_AR-NN_MA, NNAR-Linear_MA, NN_AR, Adaptive NN tahminlerinin üzerinden en başarısız sonuçlar lineer modellerden alınmıştır. Uygulamada sadece tarihsel satış verisi kullanılmıştır. Sonraki çalışmalarda başka faktörler eklenerek performansın artırılması beklenmektedir.

Thomassey ve Fiordaliso (2006), “A hybrid sales forecasting system based on clustering and decision trees Available” çalışmasında Fransız bir tekstil distribütör firmasından 1998 ile 1999 yıllarında alınan 482 günlük satış verileri kullanılmıştır. Modelin doğruluğunu ölçmek için test verisi olarak 2000 yılına ait 285 günlük satış verisi kullanılmıştır. Satış değerlerini karşılaştırmak ve kümelemek için test ve eğitim setleri haftalık değerlere çevrilmiştir.

Satış verisi yanı sıra satışlara etki eden birçok faktör bulunmaktadır. Ancak genellikle satış ve talebe etki eden faktörler firmanın veritabanında yeterince detaylı olarak bulunmamaktadır. Bu çalışmada veri farklı kümelere göre gruplanıp her biri için karar ağacı yöntemiyle tahmin yapılmıştır. Buradaki kümeleme işlemi sayesinde elde edemediğimiz faktörlere ihtiyaç duymadan profil oluşturup bu profiller sayesinde satın alma davranışı modellenebilmektedir. Profilleri oluştururken firmanın veri tabanında bulunan fiyat, satışların başlangıç zamanı, ürün ömrü modelde kriter olarak kullanılmıştır. Stil veya tekstil malzemesi gibi ek kriterler de tahmin amaçlı olarak kullanılmıştır.

Ni ve Fan 2011 yılındaki çalışmalarında uzun vadeli tahminlerde (yıllık, çeyrek, aylık tahminler) ve kısa vadeli tahminlerde (haftalık, günlük tahminler) tahminlemenin kesinliğine odaklanmıştır. AR modeliyle yapay sinir ağları/Karar ağaçları yönetimini hibrit olarak kullanarak yeni bir model oluşturulmuştur. Bu model performansı bu veri üzerinde diğer yöntemlere kıyasla daha iyi sonuç vermiştir.

Sagaert ve diğerleri, 2018 yılındaki çalışmada makroekonomik öncü göstergeler kullanarak taktiksel satış tahminlerini iyileştirmek için çeşitli yaklaşımları önermiştir. Geleneksel tahmin modelleri, geçmişten tahmin edilen tek değişkenli bilgileri hesaba katmakla birlikte, ulusal ekonomik aktivitedeki yüksek artışlar veya düşüşler gibi makroekonomik olayları tahmin edemez. Pratikte bu artış ve düşüşler, çeşitli ön

yargılardan etkilenebilir, ölçeklenebilir olmayan yönetsel uzman kararları kullanılarak yönetilmektedir. Taktik satış tahminleri tipik olarak 12 aya kadar uzanmaktadır. Bu zaman ölçeğinde, ekonominin değişen özellikleri satışları önemli ölçüde etkileyebilir. Makroekonomik bilginin doğruluğu artırabileceği ve ilgili piyasa dinamikleri hakkında bilgi sağlayabileceği hipotezi altında tahminler oluşturulmuş. Ayrıca, potansiyel öncü değişkenlerin uzmanlar tarafından önden filtrelenerek, doğruluk-maliyet dengesini ölçen uzman fikri destekli modellere karşı tamamen istatistiksel model inşasını değerlendirilmiş. Önerilen yöntem belirlenen zaman serileri kriterlerine göre tahmin doğruluğunu geliştirmektedir. Çalışmada Naive, Seasonal Naive, Holt-Winters, Exponential Smoothing, ARIMA, ARI, LinReg, StepReg, LASSO gibi lineer istatistiksel yöntemler kullanılmıştır. Aralarında en iyi performansı LASSO modeli göstermiştir. Sonrasında LASSO AR modeli test edilmiştir. LASSO hibrit LASSO-AR modelinden uzun vadede daha iyi performans göstermiştir. Kısa vadede ise yakın iyilikte performans göstermiştir.

Liu ve diğerleri, “Data mining on time series: an illustration using fast-food restaurant franchise” isimli çalışmalarında, zaman serisi veri madenciliği için tek değişkenli ARIMA modelleri kullanılmaktadır. Kavram, çoklu giriş transfer fonksiyonu modelleri ve çok değişkenli ARIMA modelleri gibi çok değişkenli modellere genişletilebilir. Bu makalede ayrıca aykırı değerler ve anomalliler de incelenmiştir.

Arumugam ve Saranya (2018), “Outlier Detection and Missing Value in Seasonal ARIMA Model Using Rainfall Data” isimli çalışmalarında mevsimsel ARIMA(SARIMA) yardımıyla yağış tahmini yapılmıştır. Zaman serileri verileri olarak 2006'dan 2016'ya olan aylık yağış verileri kullanılmıştır. Ancak yağmur verilerini analiz ederken otomatik sayım ekipmanında bir bozulmanın sonucu olarak, eksik veya aşırı değerler olduğunda ne yapılacağı ciddi bir problemdir. Bu çalışmanın amacı, tahmin edilmiş SARIMA modelinden çıkan hata fonksiyonu kullanarak bu problemi açıklamanın yolları incelenmiştir. Örneklem sayısı da önemli olduğu için hatalı ölçüm olan günleri çıkarmak yerine Aykırı (outlier) değerlerini bulmak, analiz etmek daha mantıklı bir yöntemdir.

Xuan ve diğerleri 2017 yılındaki çalışmalarında, Çin'in güneyinde bulunan Guangzhou City'de bulunan büyük ölçekli bir alışveriş merkezinden saat başı soğutma yük verilerine dayanmaktadır. Veriler doğrusal olmayan davranış gösterdiği için SVR ve yapay sinir ağları yöntemleri temel alınan 4 tane veri analizi yöntemi kullanılmıştır.

Sonu olarak Chaos-SVR ve WD-SVR hibrit modelleri tek modellerden daha kompleks olmakla beraber daha iyi sonu vermiřtir.

Braun ve diğerkleri (2014), “24 hour Demand Forecasting Based on SARIMA and SVM” alıřmasında SARIMA ve SVM yntemleriyle 24 saatlik talep tahminleri zerine odaklanmıřtır. Zaman serilerinde genellikle gemiř makalelerde ARIMA modeli kullanılmıřtır. Makine ğrenmesi algoritmalarının poplerliğinin artmasıyla beraber yapay sinir ağıları ve SVM algoritmaları gibi yeni yaklařımlar zaman serilerinin incelenmesinde kullanılmaya bařlanmıřtır. Bu makalede SVR ve SARIMA modelleri kullanılmıřtır. alıřmada yeni yntemler Berlin'deki bir yerleřim blgesinden gelen su talebi verilerine zerinde uygulanmıřtır. alıřmalarda 1 saatlik ve 24 saatlik tahminler yapılmıřtır. Makalede SVR %1'ye yakın tahminde iyileřme saėlamıřtır.

Modelde ayrıca daha uzun tahmin aralıkları da denenmiřtir. Su talebi gemiř saatlerdeki taleplerden ok etkilendiğii iin daha uzun tahmin aralıklarında tahmin hatası beklendiğii gibi artmıřtır. Genel olarak SVR yntemi SARIMA ynteminden daha iyi sonu vermiřtir. SAR modeli linear bir model olduėu iin nonlinear etkileri iyi tahminleyememiřtir. SVR ve SAR yntemleri hibrit olarak yeni bir yntem olarak tahmin performansını %1 artırmıřtır. Yine de, tm modellerin greceli hatalarının deėerlendirilmesi, hataların beyaz grltden oluřmadıėını gstermiřtir, dolayısıyla modeli geliřtirmek iin hala bir marj olduėunu gstermektedir. Literatr, bu alıřmada kullanılmamıř yaėıř, nispi nem ve bulut miktarı gibi meteorolojik zelliklerin su talebi zerinde etkili olduėunu gstermektedir. Gelecek alıřmalarda uzun sreli tahmin yntemleri ve daha kk alanlar iin su talebinin incelenmesi planlanmaktadır.

Ulke ve diğerkleri (2016) “A comparison of time series and machine learning models for inflation forecasting: empirical evidence from the USA” adlı alıřmalarında, enflasyon tahminine ynelik zaman serilerini ve makine ğrenim modellerini karřılařtırılmaktadır. ABD'den 1984 ve 2014 yılları arasındaki ampirik yntemlerle tespit edilmiř on altı kořuldan (drt farklı enflasyon gstergesi ve drt farklı zamana ait veri seti kullanılarak), makine ğrenme modellerinin yedi kořulda daha doėru tahmin sonuları saėladıėını ve zaman serisi modellerinin dokuz kořulda daha iyi olduėunu gstermektedir. Ayrıca, ok deėiřkenli modeller on drt durumda daha iyi sonular verir ve tek deėiřkenli modeller sadece iki durumda daha iyidir. Bu alıřma, makine ğrenim modelinin ekirdek kiřisel tketim harcamaları (core-PCE) enflasyon tahmini iin zaman serisi modellerinden daha iyi sonu verir. Zaman serisi

modelleri(ARDL) ise çekirdek tüketici fiyatının (core-TÜFE) endeks enflasyon tahmini için daha iyi olduğunu göstermektedir. Veriler için iki tek değişkenli (AR ve Naif) ve iki çok değişkenli (VAR ve ARDL) zaman serisi modelleri ve üç makine öğrenme modeli (ANN, k-NN ve SVR) uygulanmıştır.

Xin Liu(B) ve Ryutaro Ichise 2017 yılındaki çalışmasında gıda perakendecilerinin satışlarını tahmin etmek için meteorolojik verileri kullanan derin bir öğrenme yöntemini kullanmıştır. Meteorolojik Veriler ile Gıda Satış Tahmini'ni bir Japon zinciri süpermarketi içecek satışını öngörmeye çalışmıştır. Meyve, dondurma gibi diğer hassas ürünlerin satışını öngörmek için yeni önerilen hibrit makine öğrenmesi yöntemine başvurulmuştur. Bununla birlikte, gıda satış tahminlerini gerçekleştirmede hala zorluklar bulunmaktadır, çünkü satışları ve talebi belirleyen popülasyon, süpermarket, market veya gıda perakendecisi sayısı, fiyat stratejisi, reklam kampanyaları ve belirli bir mağazanın satış alanı gibi çok sayıda faktör bulunmaktadır. Gelecekteki çalışmalarda tahminin doğruluğunu artırmak için bu faktörler hakkında daha fazla veri toplayarak model doğruluğunu artırmak planlanmaktadır. Bu çalışmada LSTM, Autoencoder, SVM, LR, RandomForest, AdaBoost, GBDT ve yeni önerilen LSTM ve Autoencoder'ın hibrit kullanıldığı bir yapay sinir ağı modeli kullanılmıştır. Yeni önerilen modelin doğruluk yüzdesi diğer yöntemlerden daha yüksek çıkmıştır. Çalışmada klasik tek değişkenli yöntemler kullanılmamıştır.

Bozkır ve Sezer'in "Predicting food demand in food courts by decision tree approaches" isimli çalışmasında etki değişkeni olarak Gün, Ay, Tatilgünleri, Kalori, Food1, Food2, Food3, Food4 bilgileri kullanılmıştır. Tahmin edilen bağımlı değişken olarak ise satış verileri, öğle akşam yemeği ve öğrenci, akademik personel, memurlar, sözleşmeli personel olarak ayrılmıştır. Tahmin modeli olarak SPSS üzerinde karar ağaçları algoritmaları kullanılmıştır. Sonuç olarak, R kare'e 0.83'e kadar tahmin doğruluğu elde edilmiştir. Bu çalışma ile karar ağacı metodolojisinin gıda tüketim tahminine uygun olduğu gösterilmiştir.

Martínez ve arkadaşlarının (2018) yılındaki çalışmalarında mevsimsel bir model sergileyen zaman serileri ile başa çıkmak için yeni bir yöntem önerilmiştir. Model, kNN regresyon kullanarak zaman serileri tahmin etmeyi amaçlanmıştır. Modeldeki temel fikir, her farklı mevsimi farklı bir uzman k NN test verisi kullanarak sunmaktır. Her bir veri ayrı bir özneliktir çünkü eğitim seti yalnızca o mevsimi tahmin edebilen eğitim setleri içermektedir. Bu şekilde, uzman bir KNN test verisinin tahmini, aynı

mevsime ait hedef değerlerin bir araya getirilmesi yanıltıcı tahminlerin yapılma ihtimalinin azaltmıştır. Model sadece kNN'ye uygulanmıştır ve SARIMA, Holtwinters gibi klasik yöntemlerle karşılaştırılmıştır. Makalede veri seti olarak NN5 yarışmasının veri seti kullanılmıştır. Sonuç olarak bu yeni önerilen model zaman serilerinde kNN yönteminden daha iyi sonuç vermektedir.

Francis ve Kusiak “Prediction of engine demand with a data-driven approach” isimli çalışmalarında geçmiş verilere göre motor talebinin hacmini tahmin eden modeller geliştirilmiştir. Mevsimsel etkilere uyum sağlamak için, sinir ağları ve otoregresif entegre hareketli ortalama (ARIMA) yaklaşımları düşünülmektedir. Sinirsel ağların, mevsimselliği ve ham verileri kullanan trend ile model fenomenleri üzerindeki etkinliği hakkında daha önceki araştırmalar sonuçsuz kalmıştır. Bu yazıda, mevsimselliğe sahip lineer zaman serileri için dört tahmin modeli geliştirilmiş ve bunların doğruluğu çalışılmıştır. Kukla değişken lineer regresyon modelinin performansı, mevsimsel ARIMA modeli, ham tarihsel verileri kullanan nöral ağ modeli ve hibrit doğrusal model karşılaştırılmıştır. Mevsimsel ARIMA ve lineer regresyon modellerinin nöral ağ modelinden daha iyi performans gösterdiği bulunmuştur. Hibrit doğrusal modelin üç bireysel modeli daha iyi performans gösterdiği bulunmuştur.

3.2 Literatürde Hava Durmunun Satış Tahminine Etkisi İle İlgili Çalışmalar

Pazarlama araştırmaları genellikle, ürün ve hizmetler için neden, ne, nerede ve ne zaman satın alınacağı gibi müşteri satın alma kararlarını anlamaya odaklanır. Talebi etkileyen faktörlerin müşteri satın alma kararları üzerinde önemli etkileri vardır. Talebi etkileyen faktörler arasında hava, kontrol edilemeyen bir dış faktördür. Bu kontrol edilemeyen faktörle uğraşmak genellikle perakendeciler tarafından zor ve rahatsız edici bir görev olarak kabul edilir. Düzgün bir şekilde analiz edilmeyen hava, zayıf satış performansına sebep olabilir. Bununla birlikte, hava koşullarındaki oynaklığının, arz, talep ve operasyonel faaliyetler üzerinde önemli bir etkisi vardır. Hava genellikle, müşterinin satın alma kararlarını etkileyen ve talebin herhangi bir yönde hareket etmesine neden olan, kontrol edilemeyen bir faktör olarak ifade edilir. Böyle bir risk genellikle endüstrilere zarar verir. Bununla birlikte, hava ve perakende alışverişle ilgili çok az sayıda araştırma literatürde mevcuttur. Bu çalışmanın amacı, satış tahmini yapmak için bir model geliştirmek, modelleri karşılaştırmak ve perakende alışverişine

etki eden başta hava değişkenleri olmak üzere değişkenlerin satış değerleriyle ilişkisini (yani mağaza trafiğini ve satışlarını) analiz etmektir.

Bahng ve Kincade 2012 yılında “The relationship between temperature and sales: Sales data analysis of a retailer of branded women's business wear” isimli bir çalışma yayınlamışlardır. Bu çalışmanın sonuçları, sıcaklıktaki dalgalanmaların mevsimsel giysilerin satışını etkileyebileceğine dair güçlü kanıtlar sunmaktadır. Bu çalışmada, Güney Koreli bir firmanın günlük satış değerleri ve hava sıcaklığı günlük değerleri kullanılmıştır. Sıcaklık satış ilişkisi korelasyon ve t_testi uygulanarak incelenmiştir. Önemli sıcaklık değişikliklerinin meydana geldiği satış dönemlerinde daha mevsimlik giysiler satılır. Bununla birlikte, sıcaklık günden güne veya haftadan haftaya değişir, bütün mevsimde satılan kıyafetlerin sayısını etkilemez. Aynı sezon içerisinde satılması beklenen mevsimlik giysilerden, her bir ürün kategorisinin satış süreleri, kumaşın türüne ve tasarımına bağlı olarak farklılık gösterir. Bazı mevsimlik giysiler için, gerçek satış tarihleri, bir haftadan iki haftaya kadar, malların tahminlerine göre farklılık gösterir. Bu da gösteriyor ki sıcaklık ürün karakteristiğine göre satış rakamlarına etki etmektedir.

Arunraj ve Ahrens (2016) yılında yayınladıkları Estimation of non-catastrophic weather impacts for retail industry isimli makalesinde diğerlerinden farklı olarak birden fazla perakende sektöründe mağazalar seçilerek hava durumunun satışları günlük nasıl etkilediği incelenmiştir. Makalede üç ana etkiden bahsedilmiştir. Birincisi satın alınacak ürüne etkisi, ikincisi mağaza trafiğine etkisi, üçüncüsü de gecikme etkisidir. Kar kalınlığı, nem, sıcaklık, güneşlenme süresi, bağıl nem, sıcaklık sapması, faktörlerinin mağaza trafiği ve havanın insanların psikolojisine etkisi üzerinden satışlara etkisi incelenmiştir. Çıkan sonuçlara göre, kar yağışının, mağaza trafiği ve hem gıda hem de moda perakende satış mağazalarındaki satışlar üzerinde önemli bir etkisi olduğu ortaya koyulmuştur. Gıda perakende mağazasında, kar yağışı nedeniyle oluşan risk, mağazaların bulunduğu yere göre değişir. Popüler bir tekstil perakende mağazasında kar yağışının önemli ölçüde gecikme etkisi vardır. Yağışların gıda perakende mağazalarındaki sadece mağaza trafiğinde önemli bir etkisi vardır. Bu etkilere ek olarak, moda perakende mağazasındaki satışlar sıcaklık sapmasından büyük ölçüde etkilenir. Hava değişkenleri ve diğer talep etkileyen faktörler (örneğin promosyon, turizm, çevrimiçi alışveriş, müşterilerin demografisi vb.) verilerdeki sınırlamalar, önerilen MLR-AR modelinin verimliliğini azaltabilir. Bu sınırlamalara

rağmen, bu çalışma hava değişkenlerinin mağaza trafiği ve satış üzerindeki etkilerini ölçebilmektedir. Model olarak MLR ve MLR_AR yöntemleri kullanılmıştır. AR hata serisine MLR uygulanarak zamansal etkinin yanı sıra diğer faktörler de modele dahil edilmiştir. Makalede ayrıca gelecekteki çalışmalarda faktörlerin sadece satış rakamlarıyla ilişkisini incelemek yerine, satın alma şekli, satın alma zamanı, satın alınan ürün, satın alma sıklığı, satın alma miktarı, gibi değişkenlere etkisinin de incelemesi gerektiği söylenmektedir.

Ramanathan ve Muyldermans 2010'da "Identifying demand factors for promotional planning and forecasting: a case of a soft drink company in the UK. Int. J. Prod. Econ" isimli çalışmada İngiltere'nin önde gelen içecek firmalarından birinde satışları etkileyen faktörleri incelemiştir. Bu makalenin ana amacı promosyonel planlar için talep faktörlerini belirlemektir. Kullanılan faktörler promosyon tipi, promosyon büyüklüğü, promosyon süresi, indirim miktarı, festivaller, tatiller, sıcaklık, haftanın günleri, ürün aileleri. Makalede nedensellik ilişkisini çıkarmak için yapısal eşitlik modeli kullanılmıştır. Makale göstermiştir ki her bir ürünün satış tahmini aynı faktörlerle açıklanamaz. Talepler farklı faktörlerden etkilenmektedir. Bu da göstermektedir ki farklı ürün ve ürün gruplarının satışlarını artırmak için aynı yöntemler kullanılmamalıdır. Bazı faktörler iç dinamiklerden etkilenirken bazı faktörler dış dinamiklerden etkilenmektedir. Promosyon satışlarının altında yatan açıklayıcı faktörlerinde SEM ile ayrıştırılmasının, talep yapısına daha fazla içgörü kazandırmak ve yöneticilere tanıtım planlamasında yardımcı olmak için ilginç yeni bir yaklaşım geliştirilmiştir. Çalışma ayrıca SEM yardımıyla önemli değişkenleri ve birbirleriyle ilişkileri de ortaya koymaktadır.

Arunraj ve Ahrens (2015) yılındaki çalışmada ise müşterinin talebini artıran faktörleri tatil etkisi, ekstremler hava durumu etkisi, mevsimsellik, promosyonel ve indirimli ürünlerin etkisi, ürün karakteristiği, müşteri özellikleri diye sıralamıştır. Perakende mağaza satış tahmin modelinde Ay, Yağış Güneşlenme Süresi, Kar kalınlığı, Tatil Günleri, Promosyon, İndirim faktörleri kullanmıştır. Veri seti günlük muz satışları kullanılmıştır. Mevsimsel ARIMA yöntemi ve yapay sinir ağları, lineer regresyon ve quantile regresyon yöntemleri birleştirilerek hibrit modeller oluşturulmuştur. Bu modellerin performansları değerlendirilmiştir. Ayrıca OLS yardımıyla faktörlerin satışlara etkileri incelenmiştir. Buna göre bu çalışmada taze kar kalınlığının belirgin olarak negatif bir etkisi olduğu sonucu çıkmıştır. Kötü hava

koşullarının genelde şehir dışındaki işletmelere negatif etkisi vardır. Yakın bölgelerdeki satış merkezlerinde ise pozitif etkisi gözlenmektedir. Kar kalınlığının bu nedenle her zaman her lokasyon için negatif davranış göstermeyebilir. Ayrıca belirli aylardaki satışların belirgin olarak veri setine göre pozitif satış etkisi vardır. Mevsimsel ARIMA_Quantile modeli yapay sinir ağları ve linear ARIMA modeline göre faktörlerin nedenselliğini daha iyi açıklamaktadır. Žliobaitė ve arkadaşları (2012) çalışmalarında linear regression, k Nearest Neighbors, regression tree, moving average yöntemleri kullanılmıştır. Bu yöntemlerle 26 tahmin edici faktör seçilmiştir. Faktörleri seçmek için korelasyon kullanılmıştır. 220 ürünün 59 haftalık satış rakamını eğitim seti olarak kullanıp 60 haftalık test seti kullanılmıştır. Faktörler iç ve çevresel faktörler olarak ayrılıp iç databaseden toplanan veriler ve sıcaklık etkinlikler tatil günleri ise çevresel faktör olarak modele eklenmiştir. Çalışmada stok yönetimi açısından mutlak tahminlerin, göreceli tahminler kadar önemli olmadığını iddia edilmiştir. Öngörülen önemli bilgiler, satışların önümüzdeki hafta büyüüp büyüyeceği ve değişikliklerin ne kadar önemli olacağıdır.

Tian ve arkadaşlarının 2018 yayınladığı çalışmada Çin’de ulus çapında bir süpermarket zincirinden sağlanan 30000’den fazla ürün tipini içeren veri kullanılmıştır. Tüketicilerin alışveriş esnasında çeşit arama davranışlarını incelemek için işlem kayıtları panel verileri, cinsiyet ve yaş gibi temel tüketici özellikleri de dahil olmak üzere süpermarketin üyelik bilgileri kullanılmıştır. Çalışmada M-R modeli kullanılmıştır. Çalışmada satın alma duygusuna etki eden faktörler incelenmiştir. 3 hipotez incelenmiştir. Birincisi tüketicinin çeşit arama dürtüsü, hava daha az güneş ışığına sahip olduğunda daha yüksektir. Yüksek sıcaklıkların test edilen tüm ürünlerde daha fazla çeşitlilik arayışı yarattığını gösterir, ancak düşük sıcaklıkların arayışının yükseltmediğini göstermektedir. Hava kalitesi etkisi için, dört ürün bağlamı için oluşturulan modeller, bira tüketimi hariç, değişken AQI için pozitif ve önemli katsayılar göstermiştir. Böylece, Hava Kalitesi Hipotezi (H3) büyük ölçüde desteklenmiştir. Nem katsayısının negatif olması ve rüzgâr Hızının pozitif olması, düşük nem oranı ve yüksek rüzgâr hızının çeşitlilik arayışını arttırdığını göstermektedir.

3.3 Satış Tahmininde Literatürde Kullanılan Yöntemler Ve Faktörler

Satış tahmininde literatürde çeşitli yöntemler ve faktörler kullanılmıştır. Bunlar ağırlıklı olarak zaman serisi modelleri, sinir ağı modelleri ve makine öğrenmesi modelleri oluşturularak kullanılmıştır. Son yıllara tek değişkenli tahmin serilerinin yanı sıra çok faktörlü modeller çalışmalarda kullanılmaya başlanmıştır. Derin sinir ağı yöntemleri hem çok hem zaman serisine uygulanabilir olduğu ve çok çeşitli modelleri olması dolayısıyla çok kullanılmaktadır. Literatürde çalışmalar genellikle tek değişkenli tahmin serileri üzerinde zaman serisi ve sinir ağı modelleri yardımıyla, çok değişkenli tek çıktılı tahmin serileri üzerinde makine öğrenmesi ve sinir ağları yardımıyla yapılmıştır.

Satış tahmininde literatürde kullanılan faktörler bazı makalelerde iç ve dış faktörler olarak ayrılmıştır. İç faktörler firmanın kendi database'inden toplanan bilgiler. Dış faktörler ise tatil günleri, etkinlikler, sıcaklık vb. gibi çevresel faktörler olarak da adlandırılabilir (Žliobaitė ve arkadaşları,2012).

Benzer şekilde Arunraj ve Ahrens (2016) ve Gun ve arkadaşları (2010) makalelerinde farklı sektörlerde perakende ürün satışıyla ilgili çalışmalarda satış kararına etki eden faktörler tatil etkisi, hava durumu etkisi ve mevsimsellik olarak sınıflandırılmıştır.

Chen ve Tsai (2016) yılındaki çalışmasında mağaza lokasyon seçimi incelenmiş, etki eden faktörler iki ana başlıkta toplanmıştır. Birinci kategori çevresel faktörler(demografik özellikler, market koşulları) altında sınıflandırılmıştır. İkincisi kategori mağaza özellikleri (mağaza maliyetleri, mağaza büyüklüğü, ulaşılabilirlik) altında sınıflandırmıştır.

Lasek, Agnieszka, Nick Cercone, and Jim Saunders (2016) literatür inceleme çalışmasında satış'a etki eden faktörleri zaman (ay,hafta,haftanın günü, saat), hava durumu (sıcaklık,yağış,kar yağışı,güneşlilik), tatil (okul tatili, tatil), promosyon, etkinlikler, tarihsel veri, makroekonomik göstergeler, rekabet, sosyal medya verileri, lokasyon tipi, müşterilerin demografik özellikleri anabашlıkları altında toplamıştır. Diğer makalelerden farklı olarak sosyal medya verisi ve rekabet faktörünü de birer değişken olarak almıştır.

Boone, T., Ganeshan, R., Jain, A., & Sanders (2018) literatür incelemesi amaçlı çalışmasında tüketici analitik verisine odaklanmıştır. Büyük ve yeni veri türlerinin mevcut olduğu kaynaklara genel bir bakış sunmuştur. Bu yeni kaynaklardan elde

edilen verileri kullanarak tüketici analitiği konusundaki gelecekteki araştırmaları ve gelecekteki potansiyel fırsatları, özellikle de talepleri tahmini üzerinde durmuştur. Yeni çağda POS cihazları, İot, sosyal medya verileri, bulut bilişim teknolojileri firmalara çok büyük boyutlu veri sağlamaktadır Çalışmada POS cihazlarından yeni nesil ödeme ortamlarından ve cihazlarından elde edilen veri, Kullanıcının satın alma öncesi incelediği diğer ürünler yani mağaza içi kullanımları, mağaza trafiği aynı anda kaç kullanıcı işlem yapıyor, kullanıcıların satın alma sürecinde izlediği yol, kullanıcıların online ortamlarda sosyal medya sitelerinde marka ya da ürünlerle ilgili bıraktığı izler'in veri olarak analiz edilmesinden bahsedilmiştir.

Satış tahmini ve hava durumunu değişkeni kullanılan çalışmaların hemen hepsinde Hava durumu etkisini gözlemlemek için sıcaklıkla ilgili bir değişken kullanılmıştır. Bunun dışında kullanılan hava durumu değişkenleri sıcaklık sapması, yoğunlaşma noktası, nem, yağış, güneşlenme süresi, rüzgar, basınç, sis, kar kalınlığı/taze kar kalınlığı (kar yağışının öncesi/sonrası) değişkenleridir.

Literatür çalışmalarında promosyon, promosyon süresi, promosyon büyüklüğü, indirim, ürün özellikleri (ürün tipi, ürün büyüklüğü, markası, fiyatı), mağaza özellikleri (mağaza giderleri, lokasyon, mağaza büyüklüğü), hafta etkisi, ay etkisi gibi iç faktörler ağırlıklı olarak kullanılmıştır. Literatürde çevresel faktörler olarak tatil günleri(tatil öncesi/sonrası), festivaller (etkinlikler), dağıtım kanalı, toplam işlem adedi, satış beklenti seviyesi, makroekonomik göstergeler, müşteri (demografik) özellikleri, sosyal medya verileri, rekabet, market koşulları, tarihsel değerler (lag) kullanılmıştır.

Aşağıdaki tabloda makalelerde kullanılan faktörlerin listesini verilmiştir. Hava Durumu değişkenleri ve bahsedilen makaleler Çizelge 3.1'de gösterilmiştir. İç faktörlerin bahsedildiği makaleler Çizelge 3.2'de listelenmiştir. Dış faktörlerin bahsedildiği makaleler Çizelge 3.3'de listelenmiştir. Bu tablolarda da görüldüğü gibi literatürde kullanılan çok değişkenli analiz için çok sayıda değişken bulunmaktadır. Bu değişkenlerin analizini ve tahmin değişkeniyle ilişkisini bulmak için çok sayıda makale yayınlanmıştır. Her durum için kullanılabilecek tek bir model bulunmamaktadır ancak zaman serisinden farklı olarak bazı durumlarda aslında lag değerlerinden daha çok sonucu etkileyen değişkenler olabilmektedir. Bu nedenle yeni çalışmalarda çok değişkenli analizler daha fazla kullanılmaktadır.

Çizelge 3.1 : Hava durumu faktörleri makaleler matrisi.

	Ortalama Sıcaklık	Sıcaklık Sapması	Yoğuşma Noktası	Nem	Yağış	Güneşlenme süresi	Ruzgar	Basınç	Sis	Kar kalınlığı / Taze Kar kalınlığı
Bahng, Y., & Kincade, D. H. (2012)	X									
Arunraj, N. S., & Ahrens, D. (2016)	X	X		X	X	X				X
Arunraj, N. S., & Ahrens, D. (2015)	X			X	X	X				X
Ramanathan, U., & Muyldermans, L. (2010)	X									
Bertrand, J. L., Brusset, X., & Fortin, M. (2015)	X									
Žliobaitė, I., Bakker, J., & Pechenizkiy, M. (2012)	X									
Liu, X., & Ichise, R. (2017, July)	X			X	X	X				
Bozkir, A. S., & Sezer, E. A. (2011)										
Tian, J., Zhang, Y., & Zhang, C. (2018)	X			X	X	X	X		X	
c, Y. R., Aghezzaf, E. H., Kourentzes, N., & Desmet, B. (2018)										
Lasek, Agnieszka, Nick Cercone, and Jim Saunders.(2016)	X				X	X				
Ni, Y., & Fan, F. (2011)	X				X					
Loureiro, A. L. D., V. L. Miguéis, and Lucas FM da Silva. (2018)										
Verstraete, Gylan, El-Houssaine Aghezzaf, and Bram Desmet	X		X	X						
Štulec, Ivana, Kristina Petljak, and Dora Naletina(2019)	X				X	X				
Tsoumakas, G. (2018)	X									
Yang, C. L., & Sutrisno, H. (2018, January)	X									

Çizelge 3.2 : İç faktörler makaleler matrisi.

	Promosyon	Promosyon Süresi	Promosyon Büyüklüğü	İndirim	Ürün Özellikleri	Mağaza Özellikleri	Hafta Etkisi	Ay etkisi
Bahng, Y., & Kincade, D. H. (2012)					X			
Arunraj, N. S., & Ahrens, D. (2016)	X						X	X
Arunraj, N. S., & Ahrens, D. (2015)	X			X				X
Ramanathan, U., & Muyldermans, L. (2010)	X	X	X	X	X		X	
Bertrand, J. L., Brusset, X., & Fortin, M. (2015)					X		X	X
Žliobaitė, I., Bakker, J., & Pechenizkiy, M. (2012)	X							
Liu, X., & Ichise, R. (2017, July)								
Bozkir, A. S., & Sezer, E. A. (2011)					X		X	X
Tian, J., Zhang, Y., & Zhang, C. (2018)				X	X			
c, Y. R., Aghezzaf, E. H., Kourentzes, N., & Desmet, B. (2018)								
Lasek, Agnieszka, Nick Cercone, and Jim Saunders.(2016)	X							
Ni, Y., & Fan, F. (2011)	X					X		X
Loureiro, A. L. D., V. L. Miguéis, and Lucas FM da Silva. (2018)					X	X		
Verstraete, Gylan, El-Houssaine Aghezzaf, and Bram Desmet							X	X
Štulec, Ivana, Kristina Petljak, and Dora Naletina(2019)						X	X	
Tsoumakas, G. (2018)					X		X	
Yang, C. L., & Sutrisno, H. (2018, January)					X	X		

Çizelge 3.3 : Dış faktörler makale matrisi.

	Tatil Günü	Festival	Makro göstergele r	Demografik Özellikler	Satış Beklenti Seviyesi	Sosyal Medy a	Rekabet	Satın Alma Sıklığı	Satın Alma davranışı	Toplam İşlem adedi	Tarihsel Değerler (lag)
Bahng, Y., & Kincade, D. H. (2012)											
Arunraj, N. S., & Ahrens, D. (2016)	X										
Arunraj, N. S., & Ahrens, D. (2015)	X										
Ramanathan, U., & Muyldermans, L. (2010)	X	X									
Bertrand, J. L., Brusset, X., & Fortin, M. (2015)											
Žliobaitė, I., Bakker, J., & Pechenizkiy, M. (2012)	X										
Liu, X., & Ichise, R. (2017, July)	X										X
Bozkir, A. S., & Sezer, E. A. (2011)											
Tian, J., Zhang, Y., & Zhang, C. (2018)	X			X				X		X	
c, Y. R., Aghezzaf, E. H., Kourentzes, N., & Desmet, B. (2018)			X								X
Lasek, Agnieszka, Nick Cercone, and Jim Saunders.(2016)	X	X		X		X	X				X
Ni, Y., & Fan, F. (2011)	X										
Loureiro, A. L. D., V. L. Miguéis, and Lucas FM da Silva. (2018)					X						
Verstraete, Gylan, El-Houssaine Aghezzaf, and Bram Desmet											
Štulec, Ivana, Kristina Petljak, and Dora Naletina(2019)	X										
Tsoumakas, G. (2018)	X	X	X								X
Yang, C. L., & Sutrisno, H. (2018, January)	X										
Boone, T., Ganeshan, R., Jain, A., & Sanders, N. R. (2018)								X	X	X	

Özellikle çok değişkenli çalışmalarda amaçlanan değişkenlerin tahmin değişkenine etkisi ve nasıl etkileğini bulmak işletmeler açısından önemlidir. Genellikle eski yöntemlerle tahminlerde genel bir davranış çıkartılabilir ancak aşırı sıcak soğuk havalar önemli günler gibi bu genel davranışı bozan anomali olan günleri bulmak satış tahmini açısından önemlidir. Bunun yanı sıra promosyonlar ve satış stratejileri açısından da ürün ya da mağaza karakteristiklerinin müşteri profiline ve satış alma davranışına etkisinin bulunması çok önemlidir. Bunların dışında ilişkileri iyi kurmak adına modelde sadece satış değerleri değil mağaza trafiği , promosyonlu promosyonsuz satışlar gibi değerlerin kullanılması nedenselliği açıklarken önemlidir. Yeni nesil çalışmalarda ise dijitalleşmenin artması satış kanallarının da artmasıyla beraber big data ve canlı tahmin yapmak gibi ihtiyaçlar ortaya çıkmaktadır. Son çalışmalarda faktörlerin bu tarz etkilerinin üstünde durması piyasa ihtiyaçlarının da bu yöne evrildiğini göstermektedir.

Literatür çalışmalarında tahmin için kullanılan yöntemler modelin kuruluş şekli bakımından iki ana başlıkta düşünülmektedir. Birinci tek değişkenli modeller ikincisi çok değişkenli modellerdir. Çalışmalarında tek değişkenli zaman serisi tahmin modeli için NAIVE, SNAIVE, Holt-Winters(HW), TBAST, ETS, ARIMA, ARI, AR, MA yöntemleri kullanılmıştır. Bunun yanı sıra tek değişkenli tahmin serilerinde dummy değişkenler ve tarihsel D-1 D-2 gibi değerler kullanılarak makine öğrenmesi yöntemleri MLR,SVR,k-NN,CART,GP yöntemleri kullanılmıştır. Makine öğrenmesi ve zaman serisi modellerinin dışında sinir ağı modelleri ANN, NN,RBF,BNN,GRNN,MLP,LTSM yöntemleri kullanılmıştır. Bunların dışında makalelerin bir kısmında sinir ağıları modelleri ya da makine öğrenmesi modelleriyle zaman seri yöntemlerinin hibrit modelleri tasarlanıp iki yöntemin de dezavantajlarını kompanse etmek amaçlanmıştır.

Çok değişkenli literatür çalışmalarda iki eğilim var. Birincisi tahmini etkileyen faktörlerin modele ve tahmine ne kadar etkilediğinin analizi yapmak. Böylece tüketici davranışını anlamak ve satışa etki eden faktörlerin bulunmasını sağlamak. Buna göre de satış tahminin kesinliğini artırmak. Promosyon kararları almak. Yönetmel ve pazarlama kararlarına yardımcı olmak amaçlanmıştır. Bunun için meta analiz,SEM gibi yöntemler kullanılmıştır. Korelasyon testleri uygulanmıştır. Özellikle hava durumuna duyarlı ürünlerin havanın beklenmeyen etkisi incelenmiştir. Makine

öğrenme yöntemleri, Yapay sinir ağları yöntemleri, SARIMA ve Lineer regresyonun hibrit kullanımı SARIMAX gibi hibrit yöntemler kullanılmıştır.

Makridakis ve Assimakopoulos (2018) yılındaki çalışması “Statistical and Machine Learning forecasting methods: Concerns and ways forward” da 3003 tane veri seti olan M3 yarışmasından alınan farklı periyotlu mikro, makro, sektörel birçok farklı zaman serisiyle yaptıkları çalışmalarında 8 klasik zaman serisi yönteminin, 8 makine öğrenmesi yönteminin ve 2 tane de derin sinir ağı yönteminin performansını karşılaştırılmıştır. Tek adımlı tek değişkenli performans tahminlerinde en iyi performans klasik ETS ve ARIMA yöntemiyle elde edilmiştir. Klasik yöntemlerden sonra en iyi makine öğrenmesi yöntemi BNN ve en iyi derin sinir ağı yöntemi MLP olmuştur. Makine öğrenmesi yöntemlerinin çoğu bir rastgele yürüyüş modeli olan mevsimsel naif modelinden daha kötü sonuç vermiştir. Benzer şekilde ETS ve ARIMA yöntemi çok adımlı tek değişkenli tahminde de daha iyi performans göstermektedir.

Öte yandan Siami-Namini ve arkadaşları (2018, December) makalelerinde 12 veri setine LSTM ve ARIMA modelleri uygulanmış ve karşılaştırılmıştır. LSTM modeli çalışmada ARIMA modelinin hata oranını %85 oranından azaltmıştır. Diğer bir fiyat tahmin çalışmasında “Predicting chaotic coal prices using a multi-layer perceptron network model” MLP modeli ARIMA modeline üstünlük sağlamıştır. Loureiro ve arkadaşları (2018) çalışmalarında da çok değişkenli makine öğrenmesi yöntemleri (RF, Karar ağaçları) ve derin sinir ağları yöntemi kullanılmıştır. Derin sinir ağı yönteminin R kare değeri 0.73’tür ve diğerlerinden daha yüksektir. Ayrıca RMSE hata oranı daha azdır. Vengertsev (2014) çalışmasında MLP ve RBF ile tek adımlı tahmin ve ARIMA yöntemiyle tahmin karşılaştırılmıştır. Modeller birbirlerine yakın sonuçlar vermiştir.

Farklı farklı problemler için uygulanabilecek evrensel tahmin modeli yoktur. Bir ürünün a veri setiyle yapılan satış tahmininde başarılı olan bir modelin benzer bir veri setinde beklenen performansı göstereceğinden emin olamayız. Örnek vermek gerekirse eğer serinin önceki günlere bağımlılığı yüksekse uzun vadeli tahmin yapmak zorlaşır.

Çizelge 3.4’de makalelerde kullanılan yöntemleri, veri seti ve analizin tipinin listesi verilmiştir. Yöntem uygulanan matematiksel modeli, veri seti satış tahmini mi yoksa

başka bir durumu ölçmek için mi kullanılmıştır onu belirtmektedir. Tip ise model çok değişkenli mi tek değişkenli mi analiz yapmıştır onu göstermektedir.

Çizelge 3.4 : Yöntemler makaleler matrisi.

Yazar	Yöntem	Veri Seti	Tip
Tian, J., Zhang, Y., & Zhang, C. (2018). Predicting consumer variety-seeking through weather data analytics. <i>Electronic Commerce Research and Applications</i> , 28, 194-207.	Meta analiz	Tüketicinin çeşit arama davranışı	çok değişkenli
c, Y. R., Aghezzaf, E. H., Kourentzes, N., & Desmet, B. (2018). Tactical sales forecasting using a very large set of macroeconomic indicators. <i>European Journal of Operational Research</i> , 264(2), 558-569.	NAIVE SNAIVE Holt-Winters(HW) ETS ARIMA ARI MLR StepReg LASSO(all) LASSO(set) LASSOAR	satış tahmini	çok değişkenli
Liu, X., & Ichise, R. (2017, July). Food sales prediction with meteorological data—a case study of a japanese chain supermarket. In <i>International Conference on Data Mining and Big Data</i> (pp. 93-104). Springer, Cham.	SVM MLR RF AdaBoost GBDT LSTM+AutoEncoder	satış tahmini + hava durumu	çok değişkenli
Bohanec, M., Borštnar, M. K., & Robnik-Šikonja, M. (2017). Explaining machine learning models in sales predictions. <i>Expert Systems with Applications</i> , 71, 416-428.	Permutasyonel Önemlilik Naive Bayes Logistic Regression Classification Tree Random Forest	B2B satışı etkileyen parametreler	çok değişkenli
Voyant, C., Notton, G., Kalogirou, S., Nivet, M. L., Paoli, C., Motte, F., & Fouilloy, A. (2017). Machine learning methods for solar radiation forecasting: A review. <i>Renewable Energy</i> , 105, 569-582.	literatür incelemesi	literatürdeki solar radyasyon verileri üzerinde kullanılan makine öğrenmesi yöntemlerinin incelenmesi	çok değişkenli
Arunraj, N. S., & Ahrens, D. (2016). Estimation of non-catastrophic weather impacts for retail industry. <i>International Journal of Retail & Distribution Management</i> , 44(7), 731-753.	MLR MLR-AR	Satışa etki eden faktörlerin bulunması	çok değişkenli
Ülke, V., Sahin, A., & Subasi, A. (2018). A comparison of time series and machine learning models for inflation forecasting: empirical evidence from the USA. <i>Neural Computing and Applications</i> , 30(5), 1519-1527.	AR Naive VAR ARDL ANN k-NN SVR	Tahmin	çok değişkenli

Çizelge 3.4 (devam) : Yöntemler makaleler matrisi.

Yazar	Yöntem	Veri Seti	Tip
Lasek, Agnieszka, Nick Cercone, and Jim Saunders. "Restaurant sales and customer demand forecasting: Literature survey and categorization of methods." <i>Smart City 360°</i> . Springer, Cham, 2016. 479-491.	literatür incelemesi	literatürde kullanılan tekniklerin özeti kullanılan makaleler	çok değişkenli
Arunraj, N. S., & Ahrens, D. (2015). A hybrid seasonal autoregressive integrated moving average and quantile regression for daily food sales forecasting. <i>International Journal of Production Economics</i> , 170, 321-335.	SARIMA SARIMAX (SARIMA-MLR) S_ARIMA-QR(Quantile regression) MLP SNAIVE	satış tahmini + hava durumu	çok değişkenli
Bertrand, J. L., Brusset, X., & Fortin, M. (2015). Assessing and hedging the cost of unseasonal weather: Case of the apparel sector. <i>European Journal of Operational Research</i> , 244(1), 261-276.	MLR	Satışa etki eden faktörlerin bulunması	çok değişkenli
Žliobaitė, I., Bakker, J., & Pechenizkiy, M. (2012). Beating the baseline prediction in food sales: How intelligent an intelligent predictor is?. <i>Expert Systems with Applications</i> , 39(1), 806-815.	MLR k-NN regression tree MA	satış tahmini + hava durumu	çok değişkenli
Ni, Y., & Fan, F. (2011). A two-stage dynamic sales forecasting model for the fashion retail. <i>Expert Systems with Applications</i> , 38(3), 1529-1536.	AR+Decision Tree+ NN ile hata tahmini	satış tahmini + hava durumu	çok değişkenli
Bahng, Y., & Kincade, D. H. (2012). The relationship between temperature and sales: Sales data analysis of a retailer of branded women's business wear. <i>International Journal of Retail & Distribution Management</i> , 40(6), 410-426.	Korelasyon,t-test	Satışa etki eden faktörlerin bulunması	çok değişkenli
Ramanathan, U., & Muyltermans, L. (2010). Identifying demand factors for promotional planning and forecasting: A case of a soft drink company in the UK. <i>International Journal of Production Economics</i> , 128(2), 538-545.	SEM	Satışa etki eden faktörlerin bulunması	çok değişkenli

Çizelge 3.4 (devam) : Yöntemler makaleler matrisi.

Yazar	Yöntem	Veri Seti	Tip
Bozkir, A. S., & Sezer, E. A. (2011). Predicting food demand in food courts by decision tree approaches. Procedia Computer Science, 3, 759-763.	Decision Tree (CHAID,CART,MSDT)	satış tahmini	çok değişkenli
Loureiro, A. L. D., V. L. Miguéis, and Lucas FM da Silva. "Exploring the use of deep neural networks for sales forecasting in fashion retail." Decision Support Systems 114 (2018): 81-93.	DNN(Deep Neural Network) RF SVR ANN Decision Tree LR	satış tahmini	çok değişkenli
Verstraete, Gylia, El-Houssaine Aghezzaf, and Bram Desmet. "A data-driven framework for predicting weather impact on high-volume low-margin retail products." Journal of Retailing and Consumer Services 48 (2019): 169-177.	NN Gradient Boosting LASSO OLS	satış tahmini + hava durumu	çok değişkenli
Štulec, Ivana, Kristina Petljak, and Dora Naletina. "Weather impact on retail sales: How can weather derivatives help with adverse weather deviations?." Journal of Retailing and Consumer Services 49 (2019): 1-10.	MLR,Korelasyon analizi içecek satışları ve sıcaklık değerleri	satış tahmini + hava durumu	çok değişkenli
Tsoumakas, G. (2018). A survey of machine learning techniques for food sales prediction. Artificial Intelligence Review, 1-7.	literatür incelemesi	literatür incelemesi	çok değişkenli
Yang, C. L., & Sutrisno, H. (2018, January). Short-Term Sales Forecast of Perishable Goods for Franchise Business. In 2018 10th International Conference on Knowledge and Smart Technology (KST) (pp. 101-105). IEEE.	Regresyon, NN	satış tahmini + hava durumu	çok değişkenli
Xuan, Z., Zhubing, F., Liequan, L., Junwei, Y., & Dongmei, P. (2017).	SVR ve yapay sisnir ağları hibrit	soğutma yükü tahmini	tek değişkenli
Francis, H., & Kusiak, A. (2017).	MLR NN ARIMA LR-ARIMA	satış tahmini	tek değişkenli
Arumugam, P., & Saranya, R. (2018).	ARIMA(SARIMA)	Yağış miktarı tahmin	tek değişkenli

Çizelge 3.4 (devam) : Yöntemler makaleler matrisi.

Yazar	Yöntem	Veri Seti	Tip
Doganis, P., Alexandridis, A., Patrinos, P., & Sarimveis, H. (2006).	RBF Linear AR Holt-Winters(HW) Linear AR-NNMA Linear AR-Linear MA NNAR-NNMA NNAR-LinearMA NNAR Adaptive NN (GA)	kısa süreli raf ömrü olan yiyecek ürünlerinin satış tahmini	tek değişkenli
Liu, L. M., Bhattacharyya, S., Sclove, S. L., Chen, R., & Lattyak, W. J. (2001). Makridakis, Spyros, Evangelos Spiliotis, and Vassilios Assimakopoulos.	ARIMA MLP Bayesian Neural Network (BNN) RBF, Generalized Regression Neural Networks (GRNN) k-NN CART SVR Gaussian Processes (GP) SARIMA ETS NAIVE	fastfood restoranlarının satış tahmini M3 veri seti tahmini - satış tahmini	tek değişkenli tek değişkenli
Martínez, Francisco, et al.	Mevsimsel k-NN	NN5 - satış tahmini	tek değişkenli
Aye, Goodness C., et al. (2015): 66-79.	lineer: S-ARIMA TBAST Holt-Winters(HW) nonlineer: MSAR SETAR LSTAR ARANN NPAR SPAR GARCH GA FUZZY SARANN	güney afrikanın sezonluk toplam perakende satış adetleri- satış tahmini	tek değişkenli
Ramos, Patrícia, Nicolau Santos, and Rui Rebelo. (2015): 151-163.	ETS ARIMA	kadın ayak giyim ürünlerinin satış adetleri - satış tahmini	tek değişkenli

4. METODOLOJİ

4.1 Hata Fonksiyonları

Ortalama Mutlak Hata (MAE) ve Kök ortalama kare hatası (RMSE), sürekli değişkenlerin doğruluğunu ölçmek için kullanılan en yaygın ölçümlerden ikisidir. Hem MAE hem de RMSE, ilgili değişken bazında ortalama model tahmin hatasını ifade eder. Her iki metrik de 0 ile ∞ arasında değişebilir ve hataların negatif ya da pozitif olmasından bağımsızdır. Negatif odaklı puanlardır, bu düşük değerlerin daha iyi olduğu anlamına gelir. Ortalama kare hataların karekökünü almanın RMSE için bazı ilginç etkileri vardır. Kareler hataların ortalması alınmadan Hataların ortalaması alınmadan alındığından, büyük hatalara küçüklere kıyasla yüksek ağırlık verir. Büyük hataların özellikle istenmediği durumlarda, RMSE daha duyarlı olduğu için tercih edilir. Burdan sonuçla hataların varyansının artması RMSE'nin kesin artacağı anlamına gelmez. RMSE, hata büyüklüklerinin sıklık dağılımının varyansı ile artar.

RMSE formülünün sık sık tartışılmayan bir başka ifadesi örneklem büyüklüğü ile ilgilidir. MAE kullanarak, RMSE'ye bir alt ve üst sınır koyabiliriz. Bu iki fonksiyonu örneklem büyüklüklerine göre karşılaştırabiliriz. RMSE test setinin boyutu arttıkça MAE'den daha büyük olma eğilimindedir. Bu durum eğer farklı büyüklükteki test setlerle çalışmak gerekirse karşılaştırmalarda RMSE kullanmak sorun yaratabilir.

4.1.1 Ortalama mutlak hata

Ortalama mutlak hata (MAE), bir tahmin veri setindeki hataların ortalama büyüklüğünü yönlerini dikkate almadan ölçen hata fonksiyonudur. Test setindeki gerçek değerlerle tahmin değerleri arasındaki mutlak farkları eşit ağırlıklı ortalamasıdır. Genel gösterimi eşitlik denklem 4.1'deki gibidir.

$$MAE = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (4.1)$$

MAE, her gerçek değer ile veriye en iyi uyan çizgi arasındaki ortalama dikey mesafedir. MAE aynı zamanda her veri noktası ile en iyi uyan çizgi arasındaki

ortalama yatay mesafedir. MAE değeri kolay yorumlanabilir olduğu için regresyon ve zaman serisi problemlerinde sıkça kullanılmaktadır. Değeri 0 ile sonsuz arasında değişebilir.

4.1.2 Kök kareler karesi

Kök kareler karesi (RMSE), hatanın ortalama büyüklüğünü de ölçen ikinci dereceden bir puanlama kuralıdır. Tahmin ve gerçek gözlem arasındaki farklarının karelerinin ortalamasının kareköküdür. Genel gösterimi denklem 4.2'deki gibidir.

$$RMSE = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (4.2)$$

MAE ve RMSE, bir dizi tahmindeki hataların varyasyonunu teşhis etmek için birlikte kullanılabilir. RMSE her zaman MAE'den daha büyük veya ona eşit olacaktır; Aralarındaki daha büyük fark, örneklemdaki bireysel hataların varyansının daha büyük olmasıdır. RMSE = MAE ise, tüm hatalar aynı büyüklüktedir MAE ve RMSE, 0'dan ∞ 'a kadar değişebilir. Negatif yönelimli puanlar: Daha düşük değerler daha iyi.

4.2 Yöntemler

Bu bölümde literatürde sık kullanılan ve uygulamada kullanılacak olan satış tahmini yöntemlerinden bahsedilecektir. Bunlar zaman serileri, sinir ağları ve makine öğrenmesi yöntemleri olarak üç gruba ayrılmıştır.

Zaman içinde toplanan aynı değişkenin ölçüm dizisine zaman serisi adı verilir. Çoğu zaman, ölçümler düzenli zaman aralıklarında yapılır. Zaman serilerindeki analizin amacı serilerin davranışını incelemek ve geleceğe dair tahminler yapabilmektir. Çoğu analizde olduğu gibi, zaman serileri analizinde verinin sistematik bir düzenden ve genellikle desenin tanımlanmasını zorlaştıran rastgele hatadan oluştuğu varsayılmaktadır. Çoğu zaman serisi analiz teknikleri, deseni daha belirgin hale getirmek için gürültüyü filtrelemenin bir türünü içerir. Zaman serileri başka serilere ayrışabilir. Zaman serilerinin toplamı olarak da ifade edilebilir. Literatürde zaman serilerini ayırdığımızda 4 ana bileşenden oluşur:

Trend(Genel Eğilim) bileşeni; Uzun süreli Sabit bir düşüş yükseliş eğimi gösteren veri setlerinde bulunur.

Mevsim Bileşeni; Sabit bir zaman periodu ile tekrar eden desenler mevsimsel bileşendir. Diyelim haftasonu daha fazla satış yapan bir restaurant 7 günlük bir mevsimsel veri üretir. Bir dizi mevsimsel bileşen içeren verisetlerinde haftanın günü yılın ilk çeyreği gibi bir mevsimsel bir düzen vardır. Mevsimsellik her zaman sabit ve bilinen bir dönemdir. Bu nedenle, mevsimlik zaman serilerine bazen periyodik zaman serileri denir.

Çevrimsel Bileşen; Genellikle mevsimsel bileşenlerle karıştırılırlar. Mevsimsel bileşenlerden farklı olarak periodik olmayan döngülerdir. En az bir kaç dönemlik yükseliş alçalışlar çevrimsel bileşenlerdir.

Düzensiz Bileşen; Ayrıca “gürültü”, “düzensiz” veya “geri kalan” olarak da adlandırın, bu mevsimsel ve trend serileri kaldırıldıktan sonra orijinal zaman serisinin kalıntılarıdır. Zaman serileri bu belirttiğimiz alt bileşen serilerinin toplamı denklem 4.3’deki gibidir.

$$Y_t = T_t + S_t + C_t + I_t \quad (4.3)$$

ya da çarpımı şeklinde denklem 4.4’deki gibidir. Belli bir t döneminde Y zaman serisi ifade edilebilir.

$$Y_t = T_t * S_t * C_t * I_t \quad (4.4)$$

Klasik zaman serilerinde serinin durağan olması önemlidir. Bunun için birim kök testleri uygulanmaktadır. Testin sonucu olarak zaman serisi durağan değilse seriyi durağan hale getirmek için farkını alma ya da varsa trend ve mevsimsel etkilerden arıştırma yöntemleri kullanılmaktadır. En bilindik birim kök testi Artırılmış Dickey-Fuller testidir. Bir zaman serisinin bir eğilim tarafından ne kadar güçlü tanımlandığını belirlenmesi için kök testi kullanılmaktadır. Çok sayıda birim kök testi vardır ve Artırılmış Dickey-Fuller yaygın olarak kullanılanlardan birisidir. ADF’ye göre:

Sıfır Hipotezi (H_0), reddedilemez ve zaman serisinin bir birim kökü olduğunu ve durağan olmadığını göstermektedir. Zamana bağlı bir yapıya sahiptir. Alternatif Hipotez (H_1), boş hipotezi reddedebilir. Zaman serisinin bir birim kökü olmadığını, yani durağan olduğunu göstermektedir. Zamana bağlı bir yapıya sahip değildir.

Bu sonucu testteki p değerini kullanarak yorumlanmaktadır. Bir eşğin altındaki bir p değeri (% 5 veya % 1 gibi) boş hipotezi reddettiğimizi göstermektedir. Yani

durağandır. Aksi halde eşiğin üzerindeki p değeri boş hipotezi reddetmediğimizi göstermektedir. Yani durağan olmayan seridir. Özetle $p\text{-değeri} > 0.05$ ise verilerin birim kökü vardır. $p\text{-değeri} \leq 0.05$ ise boş hipotez (H_0) reddedilmektedir. Verilerin birim kökü yoktur ve durağandır.

Bir makine öğrenme modeli, verilerden öğrenen bir dizi parametrelili matematiksel formüldür. Makine öğrenmesinde eğitim adı verilen bir süreç vardır. Eğitim, verilere, bir takım model parametrelerine göre bir model uydurma sürecidir. Sonrasında bu eğitilerek elde edilen model veri setlerine uygulanmaktadır. Modelin kendi içinde eğitimle öğrenilen parametrelerinin yanı sıra düzenli eğitim sürecinde doğrudan öğrenilemeyecek başka tür parametreler vardır. Bu parametreler, modelin karmaşıklığı veya ne kadar hızlı öğrenmesi gerektiği gibi üst düzey özelliklerini ifade eder. Bunlara hiperparametreler denir. Makine öğreniminde, bir hiperparametre, öğrenme süreci başlamadan önce değeri ayarlanmış bir parametredir. Buna karşılık, diğer model parametrelerinin değerleri eğitimi yoluyla türetilir (Hyperparameter machine learning – Wikipedia).

4.2.1 Basit ortalama ve medyan

Veri setinin analizini yapmak için en temel yöntem ortalama almadır. Bir sonraki veri noktasını serideki tüm veri noktalarının ortalaması ya da medyanı olarak hesaplayabiliriz. Başka bir deyişle, bu model denklem 4.5'deki gibi hesaplanır. F_{n+1} gelecek döneme ait tahmin değeridir (Kotu ve Deshpande, 2014).

$$F_{n+1} = \text{ORTALAMA}(F_n + \dots + F_1) \quad (4.5)$$

4.2.2 Naive mevsimsel naive modelleri

Bu modeller, eldeki en son gözlem değerinin bir sonraki dönem için en iyi öngörü değeri olarak alınabileceği varsayımını yapan modellerdir. Denklem 4.6'daki gibi hesaplanır.

$$F_{n+1} = F_n \quad (4.6)$$

Naive yöntem en uygun maliyetli hızlı tahmin modelidir ve daha sofistike modellerin karşılaştırılabileceği bir ölçüt sağlar. Bu yöntem yalnızca zaman serisi verileri için uygundur. Bu yöntem, genellikle güvenilir ve doğru bir şekilde tahmin edilmesi zor

kalıplara sahip rastgele yürüyüş (randomwalk) davranışı gösteren ekonomik ve finansal zaman serileri için oldukça iyi sonuç verir.

Eğer zaman serilerinde mevsimsellik olduğuna inanılıyorsa, tahminlerin son sezondaki değere eşit olduğu yerlerde mevsimsel naif yaklaşım daha uygun olabilir. Mevsimsel Naive modeli ise benzer şekilde mevsim etkisi yüksek olan serilerde en son sezonsal gözlem değerinin bir sonraki dönem için en iyi öngörü değeri olarak alınabileceğini varsayar. Zaman Serilerinde mevsimsel bileşenin tahmininde de kullanılan çalışmalar vardır (Xiong ve Bao 2018).

4.2.3 Hareketli ortalama

Basit ortalamadan farklı olarak hareketli ortalama yönteminde veri içindeki önceki değerlerin ortalamasını almak yerine önceki n tane değer ortalaması alınır. Finansal uygulamalarda, basit hareketli ortalama önceki n verisinin ağırlıksız ortalamasıdır. Ancak, bilim ve mühendislikte, ortalama normalde merkezi bir değer her iki tarafındaki eşit sayıda veriden alınır. Bir dizi uygulama için, sadece 'geçmiş' veriler kullanılarak başlatılan hareketli ortalama kullanmamak daha uygundur. Böyle durumlarda Merkezi Hareketli Ortalama kullanılır.

Nisan ayı verilerini tahmin etmek için, son üç ayı kullanarak üç aylık bir ortalama alıyoruz. Mart ayına ait gerçek veriler geldiğinde ise Nisan değeri Mart (n), Şubat ($n-1$) ve Ocak ($n-3 + 1$ veya $n-2$) kullanılarak tahmin edilir. Bu model, verilerde mevsimsellik olduğunda kötü sonuç verebilir (Kotu ve Deshpande, 2014).

4.2.4 Üstel düzeltme yöntemleri

1950'lerin sonlarında önerilen üssel düzeltme, tahmin yapmak için zaman serileri verilerine uygulanabilecek bir başka tekniktir. Basit hareketli ortalamada, geçmiş gözlemler eşit olarak ağırlıklandırılırken, üssel pürüzsüzleştirme, zamanla üssel olarak azalan ağırlıklar kullanır. Gözleme ne kadar yeni olursa, ilişkili ağırlık o kadar yüksek olur (Lasek ve Saunders, 2016).

4.2.4.1 Basit üstel düzeltim yöntemi

Basit Üstel Düzeltim yöntemi (SES) belirgin trend ve mevsimsellik içermeyen serilerin tahmininde kullanmaya uygun bir yöntemdir. Düzleştirme faktörü veya düzleme katsayısı olarak da adlandırılan alfa (α) adı verilen tek bir parametre kullanır.

Bu parametre, önceki zamanlardaki gözlemlerin etkisinin katlanarak azaldığı oranı kontrol eder. Alfa genellikle 0 ile 1 arasında bir değere ayarlanır. Büyük değerli bir alfa değeri kullanılmışsa, model temel olarak en son yapılan gözlemlere dikkat ettiği anlamına gelir. Küçük değerler kullanılmışsa, tahmin yapılırken geçmişin daha fazla dikkate alındığı anlamına gelir. 1'e yakın bir değer hızlı öğrenmeyi gösterir (yani, yalnızca en son değerler tahminleri etkiler), 0'a yakın bir değer ise yavaş öğrenmeyi gösterir (geçmiş gözlemler tahminler üzerinde büyük bir etkiye sahiptir) (Shmueli ve Lichtendahl, 2016). Tahmin denklemi 4.7'deki gibi hesaplanır.

$$\hat{y}_{t+h|t} = l_t \quad (4.7)$$

Düzleştirme denklemi denklem 4.8'deki gibidir.

$$l_t = \alpha y_t + (1 - \alpha) l_{t-1} \quad (4.8)$$

l_t : gelecek dönem tahmini, α düzeltme faktörüdür. y_t t periodunda gerçekleşen talep, l_{t-1} geçmiş dönem değeri

Hiper Parametre: Alpha: Düzeltme faktörü

4.2.4.2 Çift üstel düzeltim yöntemi

Holt (1957), trend içeren verilerin tahminini yapılabilmesi için basit üssel düzeltmeyi biraz daha geliştirdi. Bu yöntem, bir tahmin denklemini ve iki düzgünleştirme denklemini içerir (biri seviye için, diğeri trend için):

Tahmin hesabı denklem 4.9'daki gibi hesaplanır.

$$\hat{y}_{t+h|t} = l_t + hb_t \quad (4.9)$$

Seviye hesabı denklem 4.10'daki gibi hesaplanır.

$$l_t = \alpha y_t + (1 - \alpha) (l_{t-1} + b_{t-1}) \quad (4.10)$$

Trend hesabı denklem 4.11'deki gibidir.

$$b_t = \beta * (l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (4.11)$$

l_t : gelecek dönem tahmini, α düzeltme faktörü, y_t t periodunda gerçekleşen talep, l_{t-1} geçmiş dönem değeri, β trendeki düzeltme faktörü, b_t trend tahmini, h tahmin adımı, $\hat{y}_{t+h|t}$ periyot sonrası için tahmin değeridir.

Seviye için düzleştirme faktörünü kontrol etmek için alfa parametresine ek olarak, beta (b) denilen trenddeki değişimin etkisinin azalmasını kontrol etmek için ek bir düzleştirme faktörü eklenir.

Holt'un lineer yönteminin ürettiği tahminler, geleceğe sürekli olarak sabit bir trend (artan veya azalan) gösteriyor. Ampirik kanıtlar, bu yöntemlerin, özellikle uzun süreli tahminler için aşırı tahmin eğiliminde olduğunu göstermektedir. Bu gözlemden hareketle, Gardner ve McKenzie (1985), gelecekte bir süre sonra düz bir çizgiye giden trendi "hafifleten" bir parametre ortaya koydular. Sönümlü trend parametresi kullanılan yöntemlerin çok daha başarılı olduğu kanıtlanmıştır. Otomatik tahmin istendiğinde en popüler yöntemlerdendir. Düzeltme parametreleri ile birlikte α ve β^* (Holt'un yönteminde olduğu gibi 0 ile 1 arasındaki değerler ile), bu yöntem aynı zamanda bir sönümleme parametresi içerir $0 < \phi < 1$:

Tahmin hesabı denklem 4.12'deki gibi hesaplanır.

$$\hat{y}_{t+h|t} = l_t + (\phi + \phi^2 + \dots + \phi^h)b_t \quad (4.12)$$

Seviye hesabı denklem 4.13'deki gibi hesaplanır.

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + \phi b_{t-1}) \quad (4.13)$$

Trend hesabı denklem 4.14'deki gibidir.

$$b_t = \beta * (l_t - l_{t-1}) + (1 - \beta^*)\phi b_{t-1} \quad (4.14)$$

l_t : gelecek dönem tahmini, α düzeltme faktörü, y_t t periodunda gerçekleşen talep, l_{t-1} geçmiş dönem değeri, β trendeki düzeltme faktörü, b_t trend tahmini, h tahmin adımı, $\hat{y}_{t+h|t}$ periyot sonrası için tahmin değeri, ϕ sönümleme katsayısıdır.

$\Phi = 1$ ise, yöntem Holt'un doğrusal yöntemiyle aynıdır. Pratikte ϕ , sönümleme daha küçük değerler için çok güçlü bir etkiye sahip olduğundan nadiren 0,8'den düşüktür. 1'e yakın değerleri, sönümlü bir modelin sönümsüz bir modelden ayırt edilemeyeceği

anlamına gelir. Bu nedenlerden dolayı, genellikle ϕ ile en az 0,8 ve en çok 0,98 ile sınırlandırılır.

Hiper parametre:

Alpha: Seviye için düzeltme faktörü, Beta: Trend için düzeltme faktörü, Trend Type: Eklemeli ya da Çarpımsal, Dampen Type: Eklemeli ya da Çarpımsal, Phi: Sönümlleme katsayısı

4.2.4.3 Üçlü üstel düzeltim yöntemi

Üçlü üstel düzeltme yöntemi(Holt-Winters) mevsimsel değişiklikleri ve eğilimleri dikkate alır. 1960'da Holt'un öğrencisi Peter Winters tarafından önerilmiştir. Mevsimsellik, her L periyodunda kendisini tekrar eden zaman serisi verilerinde bir kalıptır. İki tür mevsimsellik vardır: doğada "mutiplicative" ve "additive". Zaman serisi verisi $\{x_t\}$ için, L = mevsimsel değişim süresi ile $t = 0$ zamanında başlar, üçlü üssel düzeltme, denklem 4.15, denklem 4.16, denklem 4.17, denklem 4.18, denklem 4.19 verilir.

$$F_{t+m} = (s_t + mb_t)c_{t-L+1+(m-1)\text{mod}L} \quad (4.15)$$

$$s_0 = x_0 \quad (4.16)$$

$$s_t = \alpha \frac{x_t}{c_{t-L}} + (1 - \alpha)(s_{t-1} + b_{t-1}) \quad (4.17)$$

$$b_t = \beta(s_t - s_{t-1}) + (1 - \beta)b_{t-1} \quad (4.18)$$

$$c_t = \gamma \frac{x_t}{s_t} + (1 - \gamma)c_{t-1} \quad (4.19)$$

sırasındaki x değerinin bir tahminidir, ($m > 0$), α veri yumuşatma faktörüdür, β trend yumuşatma faktörüdür ve γ mevsimsel değişim yumuşatma faktörüdür, $0 < \alpha, \beta, \gamma < 1$, $\{s_t\}$, t zamanının sabit bölümünün (seviye) düzleştirilmiş değerini, t b dönemi için lineer eğilimin $\{b_t\}$ tahminlerini ve $\{c_t\}$ mevsimsel faktörlerin sırasını temsil eder.

Holt (1957) ve Winters (1960), Holt'un yöntemi mevsimselliği de modele dahil edebilsin diye geliştirdi. Holt-Winters mevsimsel yöntemi, öngörü denklemini ve üçlü düzeltme denklemi içerir - biri $\ell(t)$ seviyesi için, biri $b(t)$ trend için, diğeri mevsimsel

bileşen $s(t)$ için karşılık gelen düzeltme parametreleri a ile, β * ve γ . M 'yi mevsimsellik sıklığını, yani bir yıldaki mevsimlerin sayısını göstermek için kullanırız. Örneğin, üç aylık veriler için $m = 4$ ve aylık veriler için $m = 12$.

Trend ve mevsimsellik doğrusal ya da üstel bir değişim için ekleme ya da çarpma işlemi olarak modellenebilir. Eklemeli Mevsimsellik, doğrusal bir mevsimsellik ile Üçlü Üstel Düzeltme uygulamasıdır, Çarpımsal Mevsimsellik ise üstel bir mevsimsellik ile Üçlü Üstel Düzeltme uygulamasıdır.

Additive(Eklemeli) yöntemiyle, mevsimsel bileşen gözlemlenen seri ölçeğinde mutlak terimlerle ifade edilir ve seviye denkleminde seri mevsimsel bileşen çıkarılarak mevsimsellikten arındırılır.

Çarpımsal (multiplicative) yöntemde, mevsimsel bileşen göreceli olarak (yüzde olarak) ifade edilir ve seri mevsimsel bileşen ile bölünerek mevsimsel olarak ayarlanır.

Hiper Parametreler şunlardır: Alfa; seviye için düzeltme faktörüdür. Beta; trend için düzeltme faktördür. Gama; sezonluk için düzeltme faktörüdür. Trend Türü; eklemeli ya da çarpımsal olabilir.

Sönümleme Türü; eklemeli ya da çarpımsal, Phi; sönümleme katsayısı, Mevsimsellik Türü; Eklemeli ya da çarpımsal olabilir. Dönem; mevsimsel dönemde zaman basamaklarıdır.

4.2.5 Entegre (Karma) otoregresif hareketli ortalamalar

4.2.5.1 Otoregresif modeller

Otoregresif model'de (AR) output değişkeni doğrusal olarak kendi önceki değerlerine ve stokastik bir terime (kusurlu bir şekilde öngörülebilir bir terim) bağlı olduğu kabul edilir. Bu nedenle model stokastik bir fark denklemi biçimindedir. Makine öğreniminde otoregresif bir model, zamana bağlı bir serideki önceki değerlerden öğrenir ve bir sonraki değeri tahmin etmek için bu değerleri regresyon modelinde girdi olarak kullanır. Hareketli ortalama modelinin aksine, otoregresif model, bir birim kökü içerebildiği için her zaman durağan değildir.

4.2.5.2 Hareketli ortalama modelleri

Hareketli ortalama modellerinde (MA) kullanılan “hareketli ortalama” terimi, talep tahmin yöntemlerinden olan “hareketli ortalama” ile karıştırılmamalıdır. Burada

hareketli ortalamadan kastedilen geçmiş dönemlere ilişkin hata terimidir. Yani bağımsız değişken olarak geçmiş dönemlerin hatası kullanılmaktadır

Hareketli ortalama modeli, hata değişkeninin doğrusal olarak stokastik (kusurlu tahmin edilebilir) bir terimin mevcut ve çeşitli geçmiş değerlerine bağlı olduğunu belirtir. AR modelinin aksine, sonlu MA modeli her zaman sabittir.

4.2.5.3 Otoregresif hareketli ortalama modelleri

Otoregresif (AR) model ve hareketli ortalama modeli(MA), daha karmaşık bir stokastik yapıya sahip olan daha genel ARMA ve ARIMA zaman serilerinin anahtar bileşenleridir. Genel ARMA modeli, 1951 Peter Whittle'ın tezinde, zaman serisi analizinde Hipotez testi olarak tanımlanmış ve 1970 yılında George E. P. Box ve Gwilym Jenkins tarafından yaygınlaştırılmıştır.

İstatistiksel özelliklerinin zaman içinde sabit olması durumunda, zaman serilerinin durağan olduğu varsayılır. Bu durumda veri setine ARMA modeli uygulanır. ARIMA modeli ise AR, MA ve ARMA modellerinin ve durağan olmayan zaman serilerini de fark alma yöntemiyle durağan hale getirilip uygulanabilir hale getiren geliştirilmiş modelidir.

ARIMA modelleri, en temel ve genel zaman serisi tahmin yöntemidir. ARIMA durağan olan ve durağan olmayan zaman serilerinin tahmin edilmesinde sıkça kullanılır. ARIMA modeli 3 parametreden oluşmaktadır. Bu parametreler ARIMA (p,d,q) şeklinde gösterilir ve p otoregresif kısım derecesini, d farklılaştırma miktarını, q ise hareketli ortalama derecesini göstermektedir. ARIMA parametrelerini kullanarak AR, MA, ARMA ve ARIMA modelleri kurulabilir. ARIMA modeli d parametresini kullanarak durağan olmayan serilerin çözümüne yardımcı olmaktadır. Durağan olan veri kümesi için ise diğer modellerden uygun olanı kullanılabilir. Genel ARIMA şekli (p, d, q)

Hiper parametreler:

p- otoregresif değer

d- fark

q- hareketli ortalama değeri

4.2.6 Mevsimsel entegre otoregresif hareketli ortalama

Zaman serileri mevsimsel deęişim (üç aylık, aylık ve haftalık vb.) gösterebilir. Bu seriler mevsimsel zaman serisi olarak adlandırılır.

Genel mevsimsel ARIMA şekli (p, d, q) (P, D, Q) s

p- otoregresif deęer

d- fark

q- hareketli ortalama deęeri


P - mevsimsel otoregresif deęer

D - mevsimsel fark

Q- mevsimsel hareketli ortalama deęeri

4.2.7 Yapay sinir aęı (ANN)

1943 yılında Mcculloach çalışmasında ilk olarak basit bir sinir aęını bir elektrik devresi olarak modellemiştir. Bu da sinir aęlarının ilk modellemesi olmuştur. Sinir aęları, insan beyninden örek alınarak modellenen, desenleri tanımak için tasarlanmış bir algoritmalar kümesidir. Duyusal verileri ham olarak algılayıp etiketleme veya kümeleme yoluyla yorumlarlar. Öğretilmiş tanıtılmış desenleri, sayısallaştırılabilen görüntü, ses, metin veya zaman dizisi gibi gerçek dünya verilerini yorumlamak için kullanılmaktadır. Etiketlenmemiş verileri, örnek girdiler arasındaki benzerliklere göre gruplandırmaya yardımcı olurlar ve üzerinde çalışacak etiketli bir veri kümesi olduğunda verileri sınıflandırabilirler. Tek bir yapay sinir aęının mimari yapısı Şekil 4.1'deki gibidir. Bir yapay sinir aęı bir öğrenme algoritmasından bir tane de aktivasyon fonksiyonundan oluşur.



Şekil 4.1 : Tekli yapay nöron; toplama fonksiyonu ve aktivasyon fonksiyonundan oluşur.

4.2.7.1 Katman sayısı

Sinir Ağlarında en az bir giriş bir çıkış katmanı bulunur. Girişte girdi sayısı kadar nöron çıkış katmanında ise çıkış değişkeninin sayısı kadar nöron kullanılır. Gizli katmandaki nöron sayısı, azdan çoğa doğru artırılmak suretiyle eğitim ve test grupları için istikrarlı sonuçlar verecek şekilde deneme yanılma metoduyla belirlenmektedir.

4.2.7.2 Öğrenme algoritması ve aktivasyon fonksiyonu

Her bir nöron kendisine gelen giriş değerlerini birleştiren bir toplama fonksiyonu ve onu diğer nörona ileten bir aktivasyon fonksiyonundan oluşmaktadır. Bunların yanı sıra yapay sinir ağlarında kullanılan farklı öğrenme algoritmaları vardır bunlardan en yaygın olarak kullanılanı geri yayımlı öğrenme algoritmasıdır. Bu eğitim fonksiyonunun en önemli özelliklerinden biri fazla öğrenme yani ezberleme ihtimalini azaltmasıdır. Böylece ağın genelleme (tahmin) yeteneğinin yüksek kalmasını sağlamaktadır. Çıkışta oluşan hata değerini geri model'e yansıtır. Bu nedenle geri yayımlı algoritmalar türevlenebilir (diferansiyelenebilir) aktivasyon fonksiyona ihtiyaç duymaktadır. En sık kullanılan aktivasyon fonksiyonları Logaritmik Sigmoid (Logsig) $1/(1+e^{-x})$, Hiperbolik Tanjant Sigmoid (Tansig) $(e^x - e^{-x}) / (e^x + e^{-x})$ ve Lineer $a.x+b$ fonksiyonlardır.

4.2.7.3 Dereceli alçalma

Dereceli Alçalma (Gradient Descent), yapay sinir ağları ve lojistik regresyon gibi makine öğrenme algoritmalarının ağırlıklarını veya katsayılarını bulmak için sıklıkla kullanılan bir optimizasyon algoritmasıdır. Bu algoritma eğitim seti üzerinde tahminler yapıp çıkan hatayı genel hatayı azaltma mantığını esas alarak çalışır. Algoritmanın amacı, modelin eğitim veri setindeki hatasını en aza indiren model parametrelerini (örneğin katsayılar veya ağırlıklar) bulmaktır. Bunu, bir hata derecesi veya bir eğim boyunca minimum hata değerine doğru hareket ettiren modelde değiştirerek yapmaktadır. Bu, algoritmaya dereceli alçalma (gradyan descent) adı verilmiştir. 3 Çeşit dereceli alçalma tipi vardır. Stokastik dereceli alçalma, grup dereceli alçalma ve küçük grup dereceli alçalma algoritmaları. Stokastik dereceli alçalma hesaplayan ve eğitim veri setindeki her bir örnek için modeli güncelleyen dereceli alçalma algoritmasının bir çeşididir. Grup dereceli alçalma eğitim veri setindeki her bir örnek için hatayı hesaplayan, ancak tüm eğitim örnekleri değerlendirildikten sonra modeli güncelleyen dereceli alçalma algoritmasının bir

varyasyonudur. Küçük grup dereceli alçalma stokastik dereceli alçalma sağlamlığı ile grup dereceli alçalma verimliliği arasında bir denge bulmaya çalışır.

4.2.8 Derin sinir ağları

Derin sinir ağları temelde birden fazla saklı katmanı olan yapay sinir ağı modeli olarak tanımlanmaktadır. Derin sinir ağları, yapay sinir ağlarında olduğu gibi karmaşık linear olmayan ilişkileri modelleyebilmektedir. Derin sinir ağı yapıları görüntü işleme tanıma, görüntü özniteliklerinin katman katman tanımlanması gibi işlerde sıklıkla kullanılmaktadır. Nesneler, kendi görsellerinin özniteliklerinin katmanlı yapısı olarak ayrıştırılır ve tanımlanır. Derin katmanlar yapısal özelliklerin ayrıştırılmasını sağlamaktadır. Böylece benzer performans sergileyen bir sığ ağ'dan daha az birimle karmaşık verilerin modellenmesi sağlanmaktadır.

Derin Sinir Ağları genellikle ileri beslemeli ağ olarak tasarlanır. İleri beslemeli ağların kullanım alanları geniştir. Bazı çalışmalarda (zaman serileri, dil işleme vb) ise tekrarlayan yapay sinir ağları(RNN) ve LSTM konularında diğer yöntemlere göre daha iyi performans göstermektedir. CNN (Convolutional deep neural networks) modeli bilgisayarlı görüntü işlemede sıklıkla kullanılmaktadır. Aynı zamanda ses işleme konusunda da CNN kullanımı görülmektedir.

4.2.8.1 Çok katmanlı algılayıcı


Çok katmanlı algılayıcı (MLP) basit bir yapay sinir ağının ilk katmanı girdi alacak şekilde tanımlanmış 3 katmanlı modelidir. Bir algılayıcı(perceptron), doğrusal bir sınıflandırıcıdır; yani, iki kategoriye düz bir çizgi ile ayırarak girişi sınıflandıran bir algoritmadır. Girdi tipik olarak x ağırlıkları ile çarpılan ve sapma(bias) eklenmiş bir vektördür. Denklem 4.20'deki gibi hesaplanır.

$$y = w * x + b \quad (4.20)$$

Bir algılayıcı, gerçek-değerli girdiden tek bir çıktı üretir. Bunu yaparken giriş ağırlıklarını kullanarak (ve bazen çıktısını doğrusal olmayan bir aktivasyon işleminden geçirerek) denklem 4.21'de görüldüğü gibi doğrusal bir kombinasyon oluşturulmaktadır.

$$y = \varphi \left(\sum_{i=1}^n w_i x_i + b \right) = \varphi (w^T x + b) \quad (4.21)$$

w, ağırlık vektörünü belirtir, x girdilerin vektörüdür, b sapma(bias) ve phi doğrusal olmayan aktivasyon işlemidir. MLP yapay sinir ağlarının ileri beslemeli ağ yapısının minimum üç katmanlı en basit halidir. Birden fazla algılayıcıdan (perceptron) oluşmaktadır (Şekil 4.2).




Şekil 4.2 : MLP örneği.


Sinyali almak için bir giriş katmanından, giriş hakkında bir karar veya tahmin yapan bir çıkış katmanından ve bu ikisi arasında, gerçek hesaplama işlemi gerçekleştirilen rastgele sayıda gizli katmandan oluşmaktadır. Bir gizli katmanı olan MLP'ler, herhangi bir sürekli fonksiyona yakınlaşabilmektedir. Çok katmanlı algılayıcılar genellikle denetimli öğrenme problemlerine uygulanmaktadır. Eğitim işlemi yardımıyla girdiler ve çıktılar arasındaki korelasyonu (veya bağımlılıkları) modellemeyi öğrenirler. Eğitim, hatayı en aza indirmek için parametrelerin, modelin ağırlıklarının ve sapmalarının ayarlanması işlemidir. MLP ayrıca genelde geriye doğru yayılma yöntemini kullanır. Geriye doğru yayılma algoritması (Back propagation), çıkan hataya göre ağırlık ve sapma(bias) ayarlamalarını yapmak için kullanarak gerçek değerlere yakınsamaya yardımcı olmaktadır. Aktivasyon fonksiyonunun türevlenme işlemidir.

4.2.8.2 Evrişimli sinir ağıları


Evrişimli sinir ağıları'nın (CNN) temel yapısı, giriş katmanı, evrişim(convolution) katmanı, havuz(sampling) katmanı, tamamen bağlı katman ve çıkış katmanından oluşur. Evrişim(convolution) katmanı, bir havuz(sampling) katmanının, havuz katmanı başka katmanlara bağlanır. CNN modeli MLP'den farklı olarak çok boyutlu data'ları işlemeye daha uygun tasarlanmıştır (Şekil 4.3, Şekil 4.4). Genelde 2 boyutlu ya da üstü boyutlu girdi'lerin işlenmesinde kullanılmaktadır (Şekil 4.5). Ancak yapay sinir ağı modellerini sınırlamamak gerekir. Literatürde farklı uygulamaları görülmektedir (Borovykh ve arkadaşları, 2017).



Şekil 4.3 : Soldaki ileri beslemeli sinir ağı, sağdaki 2 katmanlı 1x2 filtre büyüklüğü olan CNN örneği her nöron önceki katmandan iki giriş nöronundan beslenir ve ağırlıklar katmanlar arasında paylaşılır.




Şekil 4.4 : Normal iki gizli katmanlı üç katmanlı bir sinir ağı.



Şekil 4.5 : Nöronları üç boyutta (genişlik, yükseklik, derinlik) CNN örneği modelin her katmanı 3D boyutlu girdiyi nöron aktivasyonlarının 3D boyutlu çıktısına dönüştürür.

CNN yapısını anlamak için öncelikle filtre, alıcı alan, öznetelik haritası kavramlarını anlamak gerekir (Şekil 4.6).

Alıcı Alan (Receptive field), Belirlen filtrenin girdi matrisinde karşılık geldiği alandır.



Şekil 4.6 : Receptive alan görseli.

Filtre, Bazı kaynaklarda nöron ya da çekirdek diye de adlandırılır (Şekil 4.7). Evrişim Katmanı (CONV); CNN'nin ana yapı bloğu CONV katmanıdır. CONV, iki bilgi kümesini birleştiren matematiksel bir işlemidir. Öznetelik haritası (feature map) üretmek için belirlenen filtre ve girdi matrisi kullanılmaktadır. CONV katmanında yapılan işlem, belirlenen filtre matrisi ve girdi matrisinin aynı boyutlu parçalarını birer adım kaydırarak çarpıp sonucunu toplanması işlemidir. Bazı durumlarda daha küçük boyutlu öznetelik haritaları (feature map) ya da daha büyük boyutlu öznetelik haritalarına (feature map) ihtiyaç olursa bunlar için farklı kaydırma adımları belirlenebilmektedir.

1	1	1	0	0
0	1	1	1	0
0	0	1	1	1
0	0	1	1	0
0	1	1	0	0

Input

1	0	1
0	1	0
1	0	1

Filter / Kernel

Şekil 4.7 : Girdi matrisi ve filtre matrisi.

Her bir matris ve filtre matris çarpımlar toplamı öznitelik haritalarına (feature map) matris'inin bir alanını oluşturmaktadır. Her işlem beraber bir öznitelik haritası oluşmaktadır. Kaç tane filtre belirlenirse o kadar sayıda öznitelik haritası oluşmaktadır (Şekil 4.8).

1x1	1x0	1x1	0	0
0x0	1x1	1x0	1	0
0x1	0x0	1x1	1	1
0	0	1	1	0
0	1	1	0	0

Input x Filter

4		

Feature Map

Şekil 4.8 : Girdi ve filtrenin çarpılması sonucu oluşan öznitelik haritası.

Havuz Katmanı ; CONV katmanından sonra, boyutları azaltmak için genellikle havuz katmanı olur. Bu katman, boyut (parametre) sayısını azaltarak hem eğitim süresini kısaltır hem de modeli aşırı öğrenme problemine'e karşı korumaktadır. Alt kattaki havuz katmanları her bir özniteliğin haritasını bağımsız olarak örnekleyerek yüksekliği ve genişliği azaltır, derinliği bozulmadan tutar.


En popüler havuz katmanı modeli max_pooling'dir. Boyutları azaltırken havuz penceresindeki en büyük değeri seçer. Öznitelik haritasını (Feature map) küçük boyutlu örnekleme dönüştürürken gerekli bilgiyi kaybetmemektedir.

Tam Bağlı Katman (Full Connected Layer); Bu katman normal sinir ağlarındaki katmanlar gibi bütün nöronların tamamen bağlı olduğu bir katmandır. CNN'in diğer katmanlarında olduğu gibi sadece belirlenen sayıda nöron tarafından beslenmezler. Ayrıca CNN'de diğer katmanların çıktıları çok boyutlu olabilir ancak bu katman girdi olarak tek boyutlu sonuç bekler. Bu nedenle pooling katmanının çıktısının tek boyutlu bir vektöre dönüştürülmesi gerekir.

Hiper parametreler; Filtre sayısı, Filtre boyutu, stride (standart değeri 1) , padding (dolgu değeri)

4.2.8.3 Tekrarlayan sinir ağları

Tekrarlayan bir sinir ağı (RNN) sinir ağlarının özel bir modelidir. Serideki önceki değerleri kullanarak bir sonraki adımı tahmin etmeye çalışır. Aslında, RNN'lerin arkasındaki fikir gelecekteki değerleri tahmin etmek için önceki verilerden öğrenmektir. Sonraki değeri tahmin etmek için önceki verilerin hatırlanması gerekir. RNN'de, gizli katmanlar önceki verilerde toplanan bilginin depolanması için dahili depolama görevi görmektedir. Tekrarlayan bir sinir ağı aynı ağı birden çok kopyası olarak düşünülebilir. Döngü açıldığında yapı Şekil 4.9'daki gibidir.




Şekil 4.9 : RNN modelinin açık gösterimi.

Standart bir RNN'de en büyük zorluk bu ağların serideki bir kaç önceki değeri hatırlaması uzun süreli geçmiş değerleri(verileri) hatırlamaya uygun olmamasıdır. Teoride, RNN'ler, parametreler dikkatlice seçilirse bu “uzun süreli bağımlılıkları” kaldırabilecek kapasitede gözükse bile uygulamada, RNN'lerin bunları öğrenemediği görülmektedir. Bunun ardındaki sebep kaybolan eğim (Vanishing gradient) sorunudur. Bu sorunu çözmek için LSTM(Uzun-Kısa Süreli Bellek) RNN modeli geliştirilmiştir.


4.2.8.4 Uzun kısa süreli bellek ağları

Uzun vadeli bağımlılıkları öğrenebilen bu RNN türü LSTM yani Uzun Kısa Süreli Bellek Ağlar, Hochreiter & Schmidhuber (1997) tarafından literatüre tanıtılmışlardır. Verilerin daha önceki eğiliminin ezberlenmesi, tipik bir LSTM'ye dahil edilen bir bellek hattı ile birlikte bazı kapılar aracılığıyla mümkün olmaktadır (Şekil 4.10).



Şekil 4.10 : LSTM örneği.

LSTM'deki ilk adım, hangi bilgileri hücre durumundan atacağımıza karar vermektir. Bu karar “unutma kapısı katmanı” adı verilen matematiksel gösterimi denklem 4.22’deki gibi olan bir sigmoid katman tarafından verilmektedir (Şekil 4.11). h_{t-l} ve x_t değerlerine bakarak C_t hücre durumundaki her sayı için 0 ile 1 arasında bir sayı çıkarır. 1 “bunu tamamen koru” yu temsil ederken, sıfır (0) “bundan tamamen kurtulması” anlamına gelmektedir.




Şekil 4.11 : Unutma kapısı.

$$f_t = \sigma(W_f * [h_{t-l}, x_t] + b_f) \quad (4.22)$$

Bir sonraki adım, hücre durumunda depolayacağımız yeni bilgilere karar vermektir. Bunun iki kısmı var. İlk olarak, “giriş kapısı katmanı” adı verilen bir sigmoid katmanı, güncellenecek değerlere karar vermektedir (Şekil 4.12). Ardından, bir tanh katmanı,

yeni aday değerler vektörünü oluşturur. Sigmoid katmanı ve tanh katmanı denklem 4.23 ve denklem 4.24 ile hesaplanır.




Şekil 4.12 : Giriş kapısı.

$$i_t = \sigma(W_i * [h_{t-l}, x_t] + b_i) \quad (4.23)$$

$$\check{C}_t = \tanh(W_c * [h_{t-l}, x_t] + b_c) \quad (4.24)$$

Artık eski hücre durumunu, C_{t-l} , yeni hücre durumunu denklem 4.25’de olduğu gibi C_t olarak güncellenmektedir. Bir önceki adımda karar verilen yeni değerlerle eski hücre durumu birleştirip güncellenir. Önceki adımlar ne yapılması gerektiğine karar verilmişti bu adımda sadece karar doğrultusunda set güncellenmektedir (Şekil 4.13).




Şekil 4.13 : Yeni hücre durumu.

$$C_t = f_t * C_{t-l} + i_t * \check{C}_t \quad (4.25)$$

Son olarak çıkış kapısında, sonuç değerine karar verilir. Denklem 4.26’da hesaplandığı gibi önce hücre’den hangi kısımlarının filtreleneceğine karar veren sigmoid katmanından geçer. Sonrasında filtrelenen değerleri -1 ile 1 arasına indirgeyen tanh

geçirip sigmoid katmanının sonucuyla denklem 4.27’de gösterildiği gibi çarpar ki karar verdiğimiz şekilde sonuç değerini elde edilebilsin (Şekil 4.14).



Şekil 4.14 : Çıkış kapısı.

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (4.26)$$

$$h_t = o_t * \tanh(C_t) \quad (4.27)$$

4.2.8.5 Derin sinir ağlarında kullanılan hiperparametreler

Epoch; tasarlanan ağa tüm verisetinin uygulanma sayısı. Yığın Büyüklüğü (Batch size); dereceli alçalma algoritması ile ilgili bir değerdir. Yığın(batch) değerinin büyüklüğüne göre hangi dereceli alçalma (gradient descent) algoritması kullanılacak o belirlenmektedir. Nöron Sayısı; ara ya da giriş katmanlarında kullanılacak Ağ (node, düğüm) sayısı, Dropout (Bırakma); bırakma, düzenlileştirme yöntemleri gibi gerekli durumlara yavaş öğrenme sağlamaktadır. Layers; her katmana daha fazla ve çeşitli sayıda nöron ekleyerek ek hiyerarşik öğrenme kapasitesi eklemek için kullanılmaktadır. Düzenlileştirme (Regularization); bazen fazla öğrenme model için iyi değildir bunun için ağın öğrenilmesini ve güçlendirilmesini yavaşlatmak için kullanılmaktadır. Optimizasyon Algoritması; öğrenmeyi hızlandırmak veya yavaşlatmak için kullanılır. Klasik dereceli alçalma (gradient descent) yöntemine alternatif optimizasyon algoritmaları da vardır. Bunlar kullanılarak öğrenme hızı ve verimliliği değiştirilebilmektedir. Kayıp Fonksiyonu; öğrenme hızı ve ilk yükler (ağırlıklar) gibi performansı yükseltmek için kullanılmaktadır. Sinir ağların kapalı kutu tahmin yöntemlerinden oldukları için en iyi sonuçları nasıl alabileceğimizi ancak farklı katman sayıları, farklı katmanlardaki nöron sayıları ya da değişik eğitim

algoritmaları uygulayarak tecrübe edilmektedir. Hiper parametreler, model özellikleri ve tasarımı deneme yanılma yoluyla uygulanmaktadır.

4.2.8.6 Derin sinir ağlarında görülen problemler

Hesaplama süresi yüksek GPU ihtiyacı: Derin mimarilerin kullanılması sığ mimarilere kıyasla çok daha uzun sürer. 1990larda bu mimarileri kullanmak gerçekçi olmazdı ama günümüzde artan GPU kapasiteleri sayesinde yüksek hızlarda hesaplama yapılabilmektedir.

Fazla Öğrenme (Ezberleme); yapay sinir ağlarında görülen birçok problem derin sinir ağlarında da görülür. Temel olarak fazla öğrenme hesaplama süreleri problem olabilir. Derin Sinir Ağları, eklenen soyutlama katmanları nedeniyle eğitim setindeki aykırı (uç) değer bağımlılıkların modellenmesine neden olmaktadır. Bu da fazla öğrenmeye neden olmaktadır. Yani ezberlemeye yol açmaktadır. Ezberleme model için istenmeyen bir özelliktir. Bunu önlemek için düzenleştirme yöntemleri uygulanır. Budama, ağırlık eksiltme ya da seyrekleştirme fazla öğrenme(aşırı uyum) problemiyle mücadele etmeye yardımcı olur. Bunun yanı sıra düğüm seyreltme yöntemi de derin sinir ağlarına uygulanabilir bir düzenleştirme yöntemidir. Aykırı(uç) değer bağımlılıklardan kurtulmak için kullanılır. Bu yöntemleri ağı tasarlarırken ya da bazı hazır kütüphanelerde ihtiyaç halinde parametrik ya da katman olarak eklenebilir. Kaybolan Eğim (Vanishing gradient); sinir ağlarının yapısından kaynaklanan bir problem değildir. Kullanılan aktivasyon fonksiyonlarından kaynaklanan gradyan tabanlı öğrenme yöntemlerinde görülen bir sorundur. Sinir ağlarının eğitiminde giriş verileriyle çıkış değerleri hesaplanır. Hesaplanmış çıkış değerleri ile gerçek değerler karşılaştırılır ve farklılık bize bir meyil verir. Bu meyile göre geriye doğru ağırlık değerlerinde güncelleme yapılır. Geriye yayılım algoritması kullanıldığı için geriye doğru taşınır. Ağı çok karmaşıksa geriye doğru meyil değerleri sıfırlanır. Meyil olmazsa güncelleme olmaz ve ağı eğitilmesinde durmuş olur. Vanishing gradient sorunu ağı yavaş eğitilmesine neden olur.

Derin Sinir Ağlarını eğitmenin yöntemi olarak hata-düzeltilme yapısı kullanılır. Bu yukarıda da anlatılan geri yayımlı dereceli alçalma gibi yöntemler uygulanma kolaylığı ve diğer eğitim yöntemlerine göre daha iyi yerel optimuma yaklaşma başarısı nedeniyle kullanılmaktadır. Bununla birlikte, bu yöntemler özellikle DNN'ler için hesaplaması zor ve verimsiz olabilir.

Avantajlar ;

- Gürültüye yüksek toleransı vardır.
- Eğitilmeden sınıflandırma yapabilirler yani gözetimsiz öğrenme yapabilirler
- Nitelikler ve sınıflar arasında ilişki zayıf olsa da kullanılabilirler
- Regresyon modellerine birçok makine öğrenmesi algoritmasından daha yatkınlardır.
- Paralel işlem yapılabilir. Paralel işlemlerle hesaplama süreleri kısaltılabilir
- Karmaşık ve özellikle lineer olmayan ilişkileri ön tahminler olmadan modelleyebilir

Dezavantajlar;

- Eğitim süreleri uzundur bu duruma uygun kullanım alanlarında değerlendirilmelidir.
- Model için kullanılan çok fazla değişken vardır. Mimarisi bu değişkenlere göre en çok iyi modellenmelidir. Bunun için iyi bir Ağ mimarisi kurmak (gizli katman sayısı, her katmandaki düğüm sayısı, düğümlerin arasındaki ilişki), orta ve dış katmanlarda transfer fonksiyonlarının seçilmesi, bir eğitim algoritması tasarlanması, giriş ağırlıklarının belirlenmesi ve modelin durması gereken sınırların verilmesi gerekir. Bu özelliklerin hepsinin detaylı ayarlanması gerekir.
- Kara kutu denilen makine öğrenmesi modellerinden olan Sinir Ağları genellikle zor yorumlanabilir modellerdir.

4.2.9 Makina öğrenmesi yöntemleri

4.2.9.1 Çoklu lineer regresyon modeli

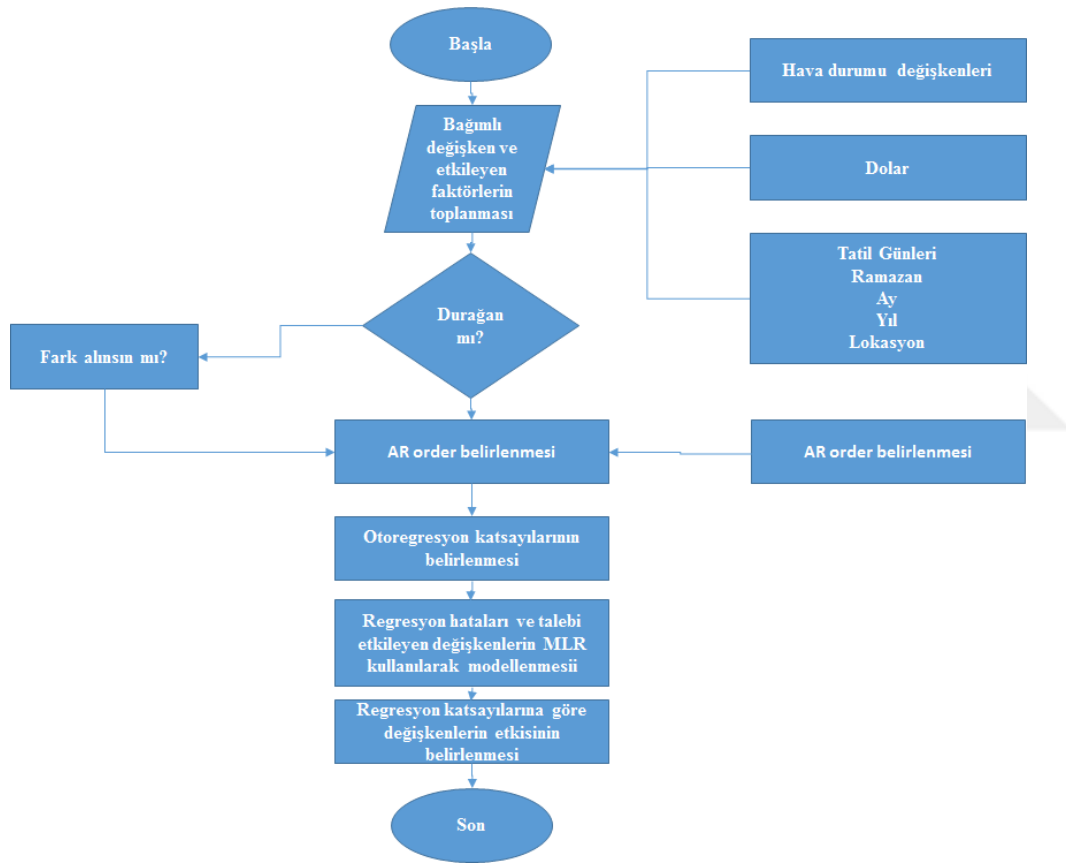
Literatürde daha önce çok sayıda makalede çok değişkenli verisetleri için çoklu lineer regresyon modeli (MLR) uygulanmış ve Regresyon katsayılarına göre etki analizi yapılmıştır.

4.2.9.2 Otomatik regresif elementlerle çoklu lineer regresyon karma modeli

Nari Sivanandam Arunraj ve Diane Ahren 2016'da yayınladıkları makalelerinde zaman serileri için karma bir model önermişlerdir. Bu modele göre bir zaman serisinde hava durumunun etkilerini modelleyebilmek için zaman serilerinin bileşenlerinin

analizi yapmandan önce çıkarılması gerekir. Diğer bir deyişle mevsimsellik ve otokorelasyon normal en küçük kareler regresyon varsayımlarını bozar. Bu nedenle önce AR yöntemi uygulanarak bu etkilerden kurtulup sonrasında regresyon hatasını lineer regresyon modelini dahil etmemizi önerirler (Şekil 4.15). MLR-AR modeli için kullanılan denklem gösterimi denklem 4.28’de mevcuttur.

$$\ln(u_t) = \beta_0 + \sum_{i=1}^5 \beta_i D_{it} + \sum_{j=1}^{11} \beta_j M_{jt} + \sum_{k=1}^{10} \beta_k H_{kt} + \sum_{l=1}^{16} \beta_l D_{lt} + \varepsilon_t \quad (4.28)$$



Şekil 4.15 : MLR-AR metodolojisi.

5. UYGULAMA: BAYİLERİN GÜNLÜK SİMİT SATIŞLARININ TAHMİN EDİLMESİ

5.1 Problem Tanımı

Verilerini kullandığımız firma, gıda sektöründe franchise olarak işletilen bir firma olarak çalışmaktadır. Bu çalışmanın amacı, simit satışlarının tahmin edilmesi ve hangi faktörlerden etkilendiğini analiz edip geleceğe yönelik ürün talebi tahminini daha sağlıklı şekilde yapmaktır. Böylece, öngörülmesi zor olan durumların tahmin edilebilir hale getirilmesi hedeflenmektedir. Bu çalışmanın bir sonraki adımı olarak saatlik satış tahmini, promosyonlar, müşteri sayısı gibi değişkenler de incelenebilir.

5.2 Veri Seti ve Modelin Belirlenmesi

Veri setini belirlerken öncelikle şirketin ihtiyaçlarını göz önünde bulundurulmuştur. Şirket, satışların ve siparişlerin tahmin edilebilmesini istemektedir. Elimizde toptan merkezden alınan sipariş verisi bulunmaktadır. Mağaza sipariş verileri mevcuttur, ancak mağaza satış verileri bulunmamaktadır. İncelendiğinde, mağazalar dondurulmuş gıda aldıkları için günlük siparişlerini günlük artan ürünlere göre hesaplayabilmektedirler. Bu nedenle, tahmin iyiliği açısından günlük siparişlerdeki değişkenlikleri satışlardaki beklentiyi net yansıtmamaktadır. Günlük sipariş ve satış sayılarında daha az fark olması için haftalık satış değerlerinin kullanılması uygun görülmüştür. Sonuç olarak, haftalık toplam sipariş sayılarını referans alınmış ve haftalık tahmin yapılmasına karar verilmiştir.

Farklı ihtiyaçlara göre yöntemlerin performansını karşılaştırabilmek için hem univariate (tek değişkenli) hem de multivariate (çok değişkenli) analiz yapılacaktır. Birincisi, tek değişkenli zaman serisi yani univariate bir data set'e zaman serisi yöntemleri uygulanacaktır. İkinci olarak da çok parametrelili zaman serisi tahmini yapılacaktır. Bunun yanı sıra diğer değişkenlerin tahmin değişkenine etkisi incelenecektir.

Çok değişkenli model için, literatür çalışmaları ve mağaza yetkililerinden alınan fikirler ışığında talebi etkileyen faktörler aşağıdaki tabloda olduğu gibi sınıflandırıldı.

Bunlar Çizelge 5.1'deki gibi dört ana başlıkta toplandı:

- Önemli Günler; Ulusal Tatiller, Okul Tatili, Ramazan,
- Makro Değişkenler; Dolar/TL,
- Mevsimsel Değişkenler; Hafta, Ay, Yıl
- Mağaza Trafiği; İl

Çizelge 5.1 : Faktör listesi.

Önemli Günler	Mevsimsel Değişkenler	Mağaza Trafiği- Lokasyon	Hava Durumu
Milli Bayramlar	Hafta Yılın kaçınıcı Haftası	İl	Sıcaklık
Okul Tatili	Ay Yılın kaçınıcı ayı		Nem
Ramazan	Yıl Ay Hafta		Kar Max sıcaklık Min Sıcaklık Güneşlenme Süresi

Bu çalışma için bir sınırlama olarak elimizde promosyon verileri bulunmamaktadır. Ayrıca, müşteri sayısını bilmediğimiz için kabaca mağaza trafiğinin ortalama olarak satışlarla aynı davranışı gösterdiği varsayılmıştır.


Ürünlerin aylık satış ortalamalarına baktığımızda, mevsimsel olarak farklı trendleri olduğu görülmüştür. Çay ya da buzlu çay gibi ürünlerde hava durumu insanların satın alma tercihini etkilemektedir. Hava durumu, mağaza yoğunluğundan çok alınan ürünün çeşidini etkilemektedir. Öncelikle mağazaların mevsimsel olarak en az etkilenen ve en çok satılan ürünü olarak simitin satış grafikleri incelenmiştir. Mevcut datadaki ürün listesine bakıldığında, en çok sipariş verilen ürün simit olduğu için simit satışlarını tahmin ettirmeye kadar verilmiştir. Diğer ürünlerde beklenen devamlılık olmadığı için simit satışları veri seti olarak daha uygundur.

5.3 Verinin Hazırlanması

5.3.1 Eksik verilerin bulunması


Gerçek verilerde genelde eksik ya da N/A değerler bulunabilir. Gerekli durumlarda bu verilerin de tahmin edilmesi gerekir. Bu işleme tamamlama (imputation) denilmektedir. Tamamlama bilinmeyen kısımları doldururken kullanılan bir kaç yöntem vardır. Zaman serisine uygun yöntemler bir de karar ağaçlarında kullanılan lineer olmayan yöntemlerdir. Bu çalışmada karar ağaçları yöntemi uygulanmıştır. Bu işlem Öncelikle incelediğimizde birçok mağazanın ilk günden son güne kadar verisinin olmadığını görüyoruz (Örnek: Şekil 5.1). Bazı dükkânlar başlangıç tarihinden sonra açılmış bazılarıysa erken kapanmıştır. Bu durumda, verimizi incelediğimizde çoğu mağazanın 2016-06 ayına kadar verisinin olduğu görülmüştür. O tarihte kapalı olmayan 2 yıllık ve 1 yıllık tam veri seti olan mağazalar referans alınmıştır. 2 yıllık data set oluşturulmuştur. Günlük veriler 2014-01-28 ile 2016-07-19 aralığı ile sınırlanmıştır. Sonuç olarak, 1 yıllık 50 tane, 2 yıllık 23 şube bilgisi bulunmaktadır. Elimideki veri seti 2 sezon içeren zaman serileri için küçük bir veri setidir. Zaman serilerinde genelde daha uzun yıllara ait verisetleri bulunur.

Şekil 5.1 istiklal şubesinde tahmin edilen aralık yeşil ile gösterilmiştir.



Şekil 5.1 : Kayıp değerlerin tahmin ettirilmesi.

Şekil 5.2’de ek veriler eklendikten sonraki istiklal şubesinin satış değerlerinin grafiği görülmektedir. Tahmin sonrası boxplot çizimlerinde Ramazan ayının satış rakamlarını düşürdüğü görülmektedir. Onun altındaki grafikte satış verisinin aylara göre boxplot çizimi görülmektedir. Aylık satış değerlerinin yanındaki grafikte haftasonu olan günlerdeki satış rakamlarıyla haftasonu olan günlerdeki satışların boxplot çizimi yer almaktadır. Bu çizime göre haftasonu satışlar hafta içine göre küçük oranda yüksek görülmektedir (Şekil 5.2). Genel olarak satış değerlerindeki trend istiklal şubesi için azalma eğilimdedir.




Şekil 5.2 : Kayıp verileri tahmin edildikten sonra veri analizi.

5.4 Veri Temizlenmesi

Öncelikle mevcut günlük veri, haftalık veri haline çevrilmiştir. Böylece iki yıllık merkezden istene haftalık simit miktarı serisi oluşturulmuştur. İkinci olarak ham günlük veriden, il bazında toplam haftalık satış değerleri olacak şekilde iki senelik veri seti oluşturulmuştur. Buna göre de sıcaklık, tatil günleri gibi faktörler kullanılarak çok değişkenli tek çıktı tahmin yapılacaktır. Ancak veriyi haftalık modele çevirmenin çok değişkenli model için handikapları olmaktadır. Burda veriyi haftalık haline getirdiğimizde anormal hava sıcaklıkları öncesi ve sonrasında satışa etkisi çok net olarak incelenememektedir. Günlük etkisi olan değişkenler tatil günleri gibi değişkenlerin etkisi normalde olduğundan daha az gözükebilmektedir.

5.4.1 Eğitim ve test kümelerinin ayrılması

Öncelikle verinin eğitim ve test datası olarak ayrılması gerekmektedir. Sıklıkla kullanılan yöntemlerden en klasik yöntem holdout seti oluşturmaktır. Bir diğeri ise çapraz doğrulama yöntemidir. Çapraz doğrulama yöntemi daha önerilmektedir. Zaman serisi için çapraz doğrulama yöntemi önerilmemektedir. Çünkü zaman serileri geçmiş değerlere bağımlı yöntemlerdir. Hyndman ve arkadaşları “A note on the validity of cross-validation for evaluating autoregressive time series prediction” çalışmalarında zaman serilerinde kullanılabilecek bir çapraz doğruya modeli önerilmiştir. Şekil 5.3’de tek adım zaman serisi tahminlerinde çapraz doğrulama veri setinin nasıl ayrılması gerektiği gösterilmiştir.




Şekil 5.3 : Tek adımlı zaman serilerinde çapraz doğrulama modeli.


5.4.2 İleri doğrulama yöntemi ile tek ve çok adımlı tahmin modelleri

Şekil 5.4’de ve Şekil 5.6’da görseller, Hyndmann ve arkadaşlarının makalesinde açıkladığı gibi zaman serisi modellerinde kullanılacak çok adımlı ve tek adımlı çapraz doğrulama işlemini anlatmaktadır. Şekil 5.5 ve Şekil 5.7’de ise yapay sinir ağı modellerinde kullanılacak tek ve çok adımlı tahmin ve çapraz doğrulama işlemi anlatılmaktadır. Kullanılan yöntemden farklı olarak seçilecek tahmin modeli uygulamanın amacına göre belirlenmelidir. Tek haftalık aylık tahmin yapılacaksa model tek adımlı eğer çok haftalık günlük tahmin yapılacaksa çok adımlı tahmin yapılmalıdır.

5.4.2.1 Tek adımlı tahmin




Şekil 5.4 : Zaman serisi yöntemlerinde kullanılan ileri doğrulama ve tek adımlı tahmin modeli.




Şekil 5.5 : Yapay sinir ağlarında supervised öğrenme modeline çevrilmiş ileri doğru tek adımlı tahmin modeli.

5.4.2.2 Çok adımlı tahmin



Şekil 5.6 : Zaman serisi yöntemlerinde kullanılan ileri doğrulama ve çok adımlı tahmin modeli.



Şekil 5.7 : Yapay sinir ağlarında supervised öğrenme modeline çevrilmiş ileri doğru çok adımlı tahmin modeli.

5.5 Kullanılan Yazılım

Yöntemleri uygulanmasında R ve Python (Anaconda) yazılımı kullanılmıştır. R, istatistik işlemler ve bu işlemlerin grafiklerinin oluşturulduğu bir yazılım dilidir. Temel olarak S yazılım dilinin farklı bir uygulaması olarak görülebilir (<http://www.r-project.org/>). R için Rstudio programı kullanılmıştır. Python kodu da Anaconda üstünde çalışan Jupyter ortamında geliştirilmiştir. Kullanılan belli başlı kütüphaneler Deep Learning için Python’da Keras kütüphanesi, zaman serileri için ise forecast paketidir. İki kütüphane de günümüzde tahmin için en çok kullanılan kütüphanelerdendir.


5.6 Yöntemlerin Veri Setine Uygulanması

Yöntemleri uygularken öncelikle tek değişkenli tahmin yapılmıştır. Tahmini yaptırırken sonuçların daha sağlıklı olması için zaman serisi tahminine de uygun olan walk-forward-validation kullanılmıştır. İkinci olarak da hem tek-adım tahmini şeklinde her seferinde bir sonraki haftayı tahmin edecek şekilde 12 haftalık tahmin yaptırıp sonuçların hatası hesaplanmıştır. Sonrasında yine tek değişkenli zaman serisi tahmini çok adımlı tahminle yapılmıştır. Test seti, 4 haftalık parçalara bölünmüştür. N uzunluğundaki eğitim setini her seferinde 4 hafta artırarak bir sonraki 4 haftalık test seti tahmin edilmiştir.

5.6.1 Tek deęişkenli/parametrelili analiz

Tek deęişkenli tahmin için kullanılacak verinin görseli Şekil 5.8'deki gibidir. Veri 2014-06-02'den başlayıp 2016 Temmuz ayına kadar mevcuttur.

Modellerin her birine kendi hiperparametrelerine uygun olarak grid search uygulanmıştır ve sonuç olarak elde edilen en iyi sonuçlu modellerin hata sonuçları devam eden bölümlerde karşılaştırılmıştır. NAIVE/SNAIVE yöntemi için naive standart ama snaive için farklı frekanslarda zaman serilerinin sonuçlarına bakılmıştır. ETS yönteminde kullanılan hiper parametreleri sırasıyla şunlardır: düzeltme katsayısı (alfa), düzeltme eğimi (beta): trend için düzleştirme katsayısı, mevsimsel yumuşatma (gama): mevsimsel bileşen için yumuşatma katsayısı, sönümlleme eğimi (phi).



Şekil 5.8 : Haftalık toplam satış değerleri.

Kullandığımız kütüphanede bu parametreleri vermezsek bile model (optimized=True) olduğu sürece parametreleri otomatik belirler. Bunların harici modelin kendi optimize etmediği, manuel verilmesi gereken parametreler bulunmaktadır.

Bunlardan biri olan trend tipinin, eklemeli (add), çarpımsal (mul) ya da bulunmayan (None) olarak belirlenmesi gerekir. Datanın mevsimsel davranışı eklemeli ise (add), çarpımsal ise (mul) veya yoksa (None) olarak kullanılması gerekmektedir. Bunlardan

başka mevsimsel periyot parametresi var eğer haftalık veri kullanıldığında (1 senede 52 hafta olduğu için) 52 olması gerekir.

Bunların dışında bu fonksiyon ön işlem olarak güç dönüşümü işlemi geçirilmek istenirse `use_boxcox` parametresi kullanılabilir. Sonrasında bu parametreleri değiştirerek en uygun model elde etmeye çalışılır. Hata sonuçlarına baktığımızda en uygun modeller aşağıdaki gibi çıkmıştır: eklemeli, damped True, mevsimsel davranış eklemeli, mevsimsel parametre 12 (Çizelge 5.2).

Çizelge 5.2 : ETS en iyi son üç sonuç.

trend	damped	seasonal	period	box_cox	remove_bias	RMSE
add'	TRUE	'add'	12	FALSE	TRUE	30.59
add'	TRUE	'add'	12	FALSE	FALSE	30.88
None	FALSE	'add'	12	FALSE	TRUE	31.06

ARIMA yöntemi için daha önce de bahsettiğimiz gibi order için p,d,q mevsimsel order için P,D,Q kullanılmaktadır. Ayrıca modelde ve hazır kullanılan kütüphanede trend olması durumunda bu trendin tipi seçilebilir. Python'da kullandığımız fonksiyonda kullanılan optimizasyon yaptığımız hiper parametreler aşağıdaki gibidir:

order: p,d,q

p- otoregressif değer

d- fark

q- hareketli ortalama değeri

seasonal order: mevsimsel model (P,D,Q)

P - mevsimsel otoregresif değer

D - mevsimsel fark

Q- mevsimsel hareketli ortalama değeri

trend: deterministik trend yoksa 'n', sabit bir trend varsa 'c' ve lineer bir trend varsa 't', kullanılır. Eğer sabit lineer bir trend varsa 'ct' kullanılmaktadır.

Bu modelde kullanışlı olabilecek parametrelerden bir tanesi de `enforce_stationarity` parametresidir. Bu tarz gelişmiş kütüphanelerde arma modellerinde durağanlık kontrolü için bu parametre kullanılmaktadır. Ayrıca Tersinirlik (`enforce_invertibility`) parametresi de kullanılmaktadır. AR (∞) gösterimindeki en son hata aşağıdaki gibi,

şimdiki ve geçmişteki hataların lineer bir fonksiyonu olarak denklem 5.1'deki gibi gösterilebilir:

$$w_t = \sum_{j=0}^{\infty} (-\theta)^j x_{t-j} \quad (5.1)$$

urdaki θ değeri $|\theta| < 1$ ise en son gözlemler, daha uzak geçmişten gelen gözlemlerden daha fazla ağırlığa sahiptir. Fakat $|\theta| > 1$ olduğunda gözlemler ne kadar uzak olursa, mevcut hata üzerindeki etkileri o kadar artar. $|\theta| = 1$ olduğunda, ağırlıklar boyut olarak sabittir ve uzak gözlemler son gözlemler ile aynı etkiye sahiptir. Bu durumlardan en doğrusu $|\theta| < 1$ olduğundan bu parametreyi TRUE olarak kullanmaktır. SARIMA sonucu elde edilen en iyi 3 sonuç Çizelge 5.3'de görülmektedir.

Çizelge 5.3 : SARIMA en iyi son üç sonuç.


order	seasonal_order	trend	RMSE
(2, 1, 2)	(1, 0, 2, 0)	'ct'	30.82
(2, 1, 2)	(0, 0, 2, 0)	'ct'	31.30
(1, 1, 2)	(2, 0, 2, 0)	't'	31.49

Derin Öğrenme yöntemlerinde tek değişkenli analiz yapabilmek için öncelikle zaman serisi verilerini durağan olacak şekilde dönüştürülmesi gerekmektedir. Eğer veride artan trend varsa ve durağan değilse trendi kaldırmak için farkı alınır. Zaman serisi denetimli bir öğrenme problemine dönüştürülebilir. Denetimli öğrenme probleminde, verilerin önceki ve sonraki adımdaki değeri, mevcut zamandaki adımdaki değerini tahmin etmek için bir girdi olarak kullanılmaktadır.

Yığın büyüklüğü parametresi (Batch size) belirlerken kullanılacak dereceli alçalma algoritmasının ne olduğun bilmek gerekmektedir. Eğer model denetimli öğrenme problemiye örnek sayısı ya da ondan daha fazla bir yığın büyüklüğü (batch size) belirlenirse model grup dereceli alçalma algoritması tarafından eğitilir. Daha küçük bir değer verilirse küçük grup/yığın dereceli alçalma algoritması kullanılmaktadır.

Küçük grup/yığın büyüklükleri (batch size) daha hızlı yakınsamaktadır ama gürültüden daha çok etkilenmektedir. Yüksek grup büyüklükleri (batch size) ise yavaş yakınsar ama daha yakın tahminler yapabilir.

MLP Modelinin katman tasarımı Şekil 5.9’da olduğu gibi uygulanmıştır. [12,50,1] Zaman Serisi olduğu için 12’li gruplar halinde veri alan ve tek output’u olan bir yapay sinir ağı olarak tanımlanmıştır. Ara katmandaki nöron sayısını n_nodes değişkeninde farklı sayılarla denenmiştir. Grid search için kullanılan hiper parametrelerden biri n_input değeri girdi sayısını belirlemektedir. Modelde bu değer 12 olarak alınmıştır. N_nodes ara katmandaki node(nöron/düğüm) sayısını belirlemektedir. N_node’un farklı değerleri [50,100] denenmiştir. N_epoch sayısı kaç kere veri setinin yakınsayacağını yapay sinir ağı yapısında işlem göreceğinin sayısıdır.



Şekil 5.9 : Oluşturduğumuz MLP model örneği girdi oniki çıktı bir.

Değeri çok yüksek olması durumunda hesaplama işlemi yavaşlayabilmektedir. Optimumu bulmak için [10,20,100] değerleriyle denedik. N_batch sayısı biraz da kullanılacak dereceli alçalma yöntemini belirlemekte, küçük sayılar küçük grup, büyük sayılar grup yöntemini kullanmaktadır. N Aktivasyon fonksiyonu olarak ‘relu’ kullanılmıştır.

Bir diğer derin sinir ağı modeli CNN yöntemi için belirlenen parametreler aşağıdaki gibidir. MLP’den farklı olarak CNN’de filtre ve çekirdek kavramlarına daha önce değinilmiştir. Grid search için bu parametrelerin farklı değerleri için tahminler yapılmıştır.

Giriş: Modele giriş olarak kullanılacak gecikme gözlem sayısı. [12]


Filtreler: Paralel filtrelerin sayısı. [64]

Çekirdek: Giriş dizisinin her okunuşunda dikkate alınan zaman adımlarının sayısı. [3,5]

N_epoch: Modeli tüm eğitim veri setine maruz bırakılma sayısı. [10,100]

N_Batch: Ağırlıklar güncellendikten sonra bir dönemin içindeki örneklerin sayısı.[1,150]

Şekil 5.10’de oluşturulan modelde kullanılan katmanlar ve nöron sayıları görülmektedir. Giriş için (12,1) girdi alınmıştır. CONV katmanı (10,64) boyutludur. Havuz katmanı (5,64) , tam bağlı katman $320=64*5$ nöronludur. CNN normalde 2-D boyutlu arraylerde daha başarılı olduğu düşünülür ancak literatürde 1-D olarak zaman serisine uygulayanlar ve başarılı sonuçlar alanlar olmuştur. Biz de 1-D olarak uyguladık. Bir CNN modeli minimum 4 katmandan oluşur. Yukarda hiper parametre olarak bahsettiğimiz fitreler CONV katmanında öznetelik seti oluşturmak için kullanılır.



Şekil 5.10 : Oluşturduğumuz CNN model örneği.

Şekil 5.10’de oluşturulan modelde kullanılan katmanlar ve nöron sayıları görülmektedir. Giriş için (12,1) girdi alınmıştır. CONV katmanı (10,64) boyutludur. Havuz katmanı (5,64) , tam bağlı katman $320=64*5$ nöronludur. CNN normalde 2-D boyutlu arraylerde daha başarılı olduğu düşünülür ancak literatürde 1-D olarak zaman serisine uygulayanlar ve başarılı sonuçlar alanlar olmuştur. Biz de 1-D olarak uyguladık. Bir CNN modeli minimum 4 katmandan oluşur. Yukarda hiper parametre

olarak bahsettiğimiz fitreler CONV katmanında öznitelik seti oluşturmak için kullanılır.


Bir sonraki yöntem LSTM yönteminde kullanılan hiper parametreler MLP yöntemiyle aynıdır. LSTM modeli Şekil 5.11’de görüldüğü gibi 12,1 boyutlu giriş katmanı, 100 nöronlu ara katmandan oluşmaktadır.

Giriş: Modele giriş olarak kullanılacak gecikme gözlem sayısı. [12]

N_nodes: Katmandaki nöron (düğüm) sayısı


N_epoch: Modeli tüm eğitim veri setine maruz bırakılma sayısı. [10,100]

N_Batch: Ağırlıklar güncellendikten sonra bir dönemin içindeki örneklerin sayısı.[1,150]




Şekil 5.11 : Oluşturduğumuz LSTM modeli örneği.

LSTM’e zaman serisi verilerini uygulamak için önce seriyi durağan hale getirmek gerekir. Sonrasında veriyi denetimli öğrenme problemine dönüştürmek gerekir. LSTM özellikle aktivasyon fonksiyonu olarak hiperbolik tanjant fonksiyonu kullanır. Bu nedenle verisetini -1 ile 1 arasında değerlere çekmek gerekir. Her deneysel senaryo 10 kere çalıştırılıp değişim incelenir. Bunun nedeni, bir LSTM ağı için rastgele başlangıç koşullarının, belirli bir konfigürasyonun her eğitilmesinde çok farklı sonuçların çıkabilmesidir. Basit bir LSTM modeli kurup 10 kere çalıştırıp sonuçlara baktığımızda çıkan hata oranları çok değişkenlik göstermektedir. Şekil 5.12’da örnek olarak LSTM hata oranlarının boxplot çizimi görülmektedir.



Şekil 5.12 : LSTM boxplot hata çizimi 52.676 RMSE (+/- 15.986).

Kıyaslamak istersek benzer Şekil 5.13’de CNN örneğinin hata sonuçlarına bakılabilir. CNN modelinde hata farkları LSTM’den belirgin şekilde düşüktür. Bu da CNN modelinin daha istikrarlı genellenebilir olduğunu göstermektedir.



Şekil 5.13: CNN boxplot hata çizimi 63.165 RMSE (+/- 1.421).

5.6.1.1 Tek adım haftalık tahmin sonuçları


Yapılan ilk analiz olan tek değişkenli analizde, zaman serilerindeki tahmin performansları karşılaştırılmıştır. Tek adımlı tahminin Çizelge 5.4’deki sonuçlarına bakıldığında, ETS ve SARIMA modellerinin sırasıyla 36 ve 34 RMSE değerleriyle yapay sinir ağları yöntemlerine yakın sonuç verdiği görülmektedir. Sonuçların grafiksel karşılaştırmaları Şekil 5.14 ve Şekil 5.15’de görülmektedir. Burada görülüyorki derin sinir ağları ve klasik yöntemler birbirlerine yakın sonuç vermektedir. Mape değeri hata fonksiyonlarından negatif hataya daha duyarlı olduğu düşünülürse derin öğrenme yöntemleri diğer modellere göre daha çok pozitif hata üretmiştir. Persiste yani naive değerden anlaşılan 4 hafta önceki veriler modeli en iyi

yasılanlardır. Benzer şekilde ortalamada son 4 haftanın verisini kullanmak daha iyi sonuç vermiştir.


Çizelge 5.4 : Tek adım oniki haftalık tahmin modeli hata sonuçları.

Model		RMSE	MAPE	MAE
persist	[4, 1, 'persist']	52,29433	18,43	36,13
mean	[1, 4, 'mean']	36,13	18,43	52,29
MA	[7, 1, 'median']	54,59	19,57	38,61
MA	[7, 1, 'mean']	55,81	20,14	39,85
MLP	[4, 50, 50, 112, 1]	34,69	10,31	21,43
CNN	[12, 32, 5, 100, 32, 1]	34,87	10,72	23,65
LSTM	12, 100, 50, 1, 1	35,82	9,91	20,67
SARIMA	[(1, 0, 2), (1, 0, 0, 0), 'ct']	34,53	20,61	21,13
SARIMA	[(2, 1, 0), (0, 0, 1, 0), 'ct']	35,02	20,51	23,65
ETS	['mul', True, None, 4, True, False]	36,70	11,90	24,69

MAPE değeri MAE ve RMSE'den daha düşüktür. RMSE test setinin boyutu arttıkça MAE'den daha büyük olma eğilimindedir. Tek adımlı tahmin modeli uygulandığı ve 12 aylık tahmin için artan bir eğitim seti olduğu için RMSE sonuçları MAE'den daha büyük olması olasıdır.



Şekil 5.14 : Tek adım tahminde yöntemlerin karşılaştırılması.



Şekil 5.15 : Tek adım tahminde yöntemlerin hata oranları.

Tek adımlı yöntemle belirlenen en iyi sonuç veren hiperparametrelere göre bütün yöntemlerin çok-adımlı 4 haftalık tahminlerini yaptık. Çıkan sonuçlara göre modellerin performanslarını kıyasladık. Bu işlem için veriyi 4 haftalık veri setlerine böldük. Derin öğrenme yöntemlerini bu 4 haftalık veri setleriyle eğittik. Böylece 4 haftalık veriden sonraki 4 haftayı tahmin ettirdik.

Ayrıca tek-adım tahmin sonuçlarında SARIMA için grid search denedik, özellikle enforce_stationary parametresini TRUE yaparak inceledik. Bulduğumuz model gerçekten uygun mu onu inceleyeceğiz.

5.6.1.2 Zaman serisi analizi

Veri setimizin özellikleri Çizelge 5.5’de görülmektedir.

Çizelge 5.5 : Veri ile ilgili genel bilgiler.

Veri seti	112
ortalama	344,347666
std	58,706911
minimum	165,844720
25%	319,885714
50%	347,099276
75%	395,329193
maksimum	43,536098


Zaman serisi analizi yaparken ilk bakılması gereken özelliklerden bir tanesi, veri setinin durağan olup olmadığıdır. Bunun analizi için çeşitli yöntemler bulunmaktadır.

Bu yöntemlerden ADF testini, Python'daki Statsmodels kutuphanesinden adfuller() fonksiyonunu kullanarak test edildi. Çizelge 5.6'daki sonuçlara göre durağan olmadığını görülmüştür çünkü ADF değerinin %1'lik kritik değerden küçük çıkması gerekirdi. Bu nedenle, 1 farkını alıp serinin ADF değerleri kontrol edilmiştir. Kritik değerlerin hepsinden küçük olduğu için yeni serinin durağan olduğu sonucuna varılmıştır.


Çizelge 5.6 : ADF değerleri.

ADF Statistic	-1.317007	before_diff
p-value	0.621356	
Critical Values		
1%	-3.494	
5%	-2.889	
10%	-2.582	
ADF Statistic	-8.791878	after_diff
p-value	0.000000	
Critical Values		
1%	-3.493	
5%	-2.889	
10%	-2.581	

Otokorelasyon grafiği incelendiğinde ve ACF/PACF grafiğinde 50'lerde ve 2, 3'üncü lag'de korelasyonun yüksek olduğu görülmektedir (Şekil 5.16, Şekil 5.17).




Şekil 5.16 : Otokorelasyon grafiği.




Şekil 5.17 : Veri setinin ACF/PACF grafikleri.

En uygun modeli seçmek için (modelin verilere ne kadar uygun olduğunu bulmak için), residuallerin de analizini yapmak gerekmektedir. Residuallerin bir beyaz gürültü davranışı gösterip göstermediğini incelemek gerekir. İyi bir model ise sıfır ortalama, sabit varyans ve seri korelasyonu olmaması gerekir. Şekil 5.18’de residuallerin çıktılarını incelediğimizde sıfır ortalamaya yakın görülmektedir. Bir kaç anomali hariç normal dağılıma yakın sonuçlar alınmıştır.



Şekil 5.18 : Residual dağılımı.

Şekil 5.19’de hata değerlerinin çizimine baktığımızda belirgin olarak ramazan aylarında büyük farklar görülmektedir, bu yukarıda belirtilen sebeplerden dolayı öngürülebilir bir durumdur.



Şekil 5.19 : Residual(Hata) değerlerinin çizimi.

5.6.1.3 Çok adım tahmin sonuçları

Çok adımlı (4 haftalık) tahmin sonuçlarında Çizelge 5.7 ve Çizelge 5.8’e göre, SARIMA, ETS, Encoder Decoder LSTM ve LSTM yöntemleri ortalama RMSE değerleriyle diğer yöntemlerden daha iyi sonuç vermiştir..


Çizelge 5.7 : Çok adımlı tek değişkenli tahmin sonuçları RMSE.

RMSE	Hafta1	Hafta2	Hafta3	Hafta4
Naive	23,296	10,973	11,789	37,454
SARIMA	14,275	24,388	19,281	11,457
ETS	14,042	38,867	39,088	42,791
CNN_Multichannel	37,132	56,124	48,156	44,722
CNN_Multiheaded	46,257	63,104	65,625	57,546
CNN	19,911	46,160	39,054	36,268
CNN Encoder Decoder LSTM	20,540	43,601	40,250	34,211
Encoder Decoder LSTM	16,688	40,918	37,606	32,190
LSTM	13,962	41,580	35,315	32,204
Conv LSTM	17,250	43,880	37,950	31,330
MLP	27,960	49,768	46,335	37,837

Çizelge 5.8 : MAE çok adımlı tek değişkenli tahmin sonuçları.

MAE	Hafta1	Hafta2	Hafta3	Hafta4
Naive	21,513	10,897	11,701	37,095
SARIMA	14,275	24,388	19,281	11,457
ETS	12,271	29,234	35,070	42,588
CNN_Multichannel	39,065	43,903	45,147	42,511
CNN_Multiheaded	37,690	35,757	36,531	35,114
CNN	18,294	30,535	25,810	24,189
CNN Encoder Decoder LSTM	22,207	29,972	30,997	25,982
Encoder Decoder LSTM	11,799	40,368	29,200	29,615
LSTM	21,169	32,028	33,350	33,878
Conv LSTM	17,307	34,078	31,249	27,617
MLP	24,399	36,250	33,322	30,660

Veri seti küçük olduğu ve sadece 2 sezon içerdiği için muhtemelen bu şekilde sonuçlar vermiştir. Tabloları incelerken uzun süreli tahminde en iyi sonuçları NAIVE yöntem, SARIMA ve CNN'in vermiş olduğu görülmektedir. Yöntemlerin karşılaştırılması Şekil 5.20'de görülmektedir. 5.20'de ham mae hem de rmse beraber incelendiğinde ARIMA, ETS, LSTM'in en iyi sonucu verdiği gösterilmiştir. Sonuçlar birbirine yakın olduğu için aslında zaman serisi modelleri derin öğrenme modellerine üstünlük sağladığı sonucu çıkarılmaktadır.




Şekil 5.20 : Yöntemlerin karşılaştırması.


5.6.2 Çok değişkenli parametre analizi

Hava durumu etkisini ölçmek için veri seti il bazında toplam haftalık değerler haline getirilmiştir. Verisetindeki örneklerin çoğu İstanbul'dan olmakla birlikte, Antalya, Bursa, Gaziantep, İzmir, Malatya, Nevşehir, Samsun illerinden birer mağaza, Sakarya'dan ise 2 tane mağaza, 2 yıllık veri setinde mevcuttur.

Bu noktada incelenmesi gereken iki konu bulunmaktadır. Birincisi, ekstrem olmayan hava durumunun satışları etkisi, ikincisi ise ekstrem hava koşulları ya da hava durumundaki değişmelerin satışları etkisidir. Mevcut veri setinde mağaza trafiği ve mağaza satış rakamları bulunmamaktadır. Sadece merkezden giden simit sayısı bulunmaktadır. Bu nedenle çalışmada havanın mağaza trafiğine etkisi ve müşterilerin satın alma davranışlarına etkisi incelenememektedir. Şekil 5.22’de illere göre satış değerlerinin boxplot çizimi görülmektedir. Şekil 5.21’de illere göre sıcaklık değerlerinin boxplot çizimi görülmektedir. Yıl içinde satış değerleri en çok farklılık gösteren il istanbuldur. İstanbul aynı zamanda veri setinde çok fazla mağaza olması nedeniyle en çok satış yapılan ildir. En çok sıcaklık değişimi nevşehir ve malatyada görülürken diğer illerde sıcaklık salınımları daha küçük aralıkda olduğu gözlenmektedir. 5.22de satış değerlerine bakıldığında Sakarya, Antalya ve İstanbul en çok satış yapılan illerdir. Sakaryada dağılımın dışında çok satışların olduğu gün sayısı diğerlerinden daha fazladır. İstanbul ilinin salınımı diğerlerinden daha fazladır.



Şekil 5.21 : İl bazında sıcaklık değerlerinin değişimi.



Şekil 5.22 : İl bazında satış rakamlarının değişimi.

Çizelge 5.9 : Sürekli değişkenlerle satış rakamlarının korelasyon değerleri-1.

	Antalya	Bursa	Gaziantep	İstanbul
	SalesCount	SalesCount	SalesCount	SalesCount
D1_Lt	0.55	-0.23	0.43	0.8
D2_Lt	-0.60	0.03	0.54	0.8
D3_Lt	0.05	0.21	-0.06	0.2
D4_Lt	0.26	-0.42	-0.06	0.9
D5_Lt	0.38	0.13	0.56	0.7
D6_Lt	0.03	0.04	0.31	0.8
Price	-0.62	0.27	-0.10	-0.4
SalesCount	1.00	1.00	1.00	1.0
temp	0.48	-0.34	-0.47	-0.6
Max_temp	0.46	-0.33	-0.45	-0.6
Min_temp	0.50	-0.33	-0.46	-0.6

Çizelge 5.9 ve 5.10'daki il bazındaki satış ve diğer değişkenler arasındaki korelasyon ilişkisini incelendiğinde mevcut parametrelerle trafiğini en çok açıklayabildiği il İstanbul'dur. Bu nedenle İstanbul'daki aylık satış değerleri hava incelemesi için referans alınmıştır.


İstanbul'da Şekil 5.24'de aylık satış grafiğine bakıldığında, Haziran Temmuz aylarında belirgin bir düşüş gözlenmektedir. Ayrıca diğer aylarda da hava ısındıkça da düşüş gözlenmiştir. Haziran Temmuz aylarında düşüş tek başına sıcaklıkla açıklanması doğru olmayabilir; söz konusu yıllarda Ramazan ayı Temmuz ve Haziran aylarına denk gelmiştir(Şekil 5.25).

Çizelge 5.10 : Sürekli değişkenlerle satış rakamlarının korelasyon değerleri-2.

İzmir	Malatya	Nevşehir	Sakarya	Samsun
-------	---------	----------	---------	--------


	SalesCount	SalesCount	SalesCount	SalesCount	SalesCount
D1_Lt	-0.32	0.258	-0.29	0.9	0.143
D2_Lt	-0.31	-0.031	0.26	0.1	0.234
D3_Lt	0.26	0.179	0.54	0.3	0.122
D4_Lt	0.24	0.305	0.48	-0.3	0.194
D5_Lt	-0.21	0.062	0.56	-0.4	-0.161
D6_Lt	0.09	0.250	0.37	-0.1	-0.051
Price	0.38	-0.366	-0.54	-0.4	0.005
SalesCount	1.00	1.000	1.00	1.0	1.000
temp	-0.57	0.008	-0.11	0.6	-0.270
Max_temp	-0.56	-0.005	-0.12	0.5	-0.262
Min_temp	-0.57	0.056	-0.06	0.6	-0.281

Şekil 5.23’de Antalyanın aylara göre satış değerleri görülmektedir.




Şekil 5.23 : Antalya aylara göre satış rakamları.

Şekil 5.23’de Antalya’nın satış rakamlarında ise yaz aylarında çok turist çeken bir bölge olmasından dolayı kabaca yaz aylarında turist etkisiyle satışlarının arttığını söyleyebiliriz. Bu da aslında sıcaklığı etkisinin il bazında farklı olduğunu göstermektedir. Modelimizde olmamasına rağmen yabancı ve yerli turist sayısını modele etkisi olduğu görülmektedir.



Şekil 5.24 : İstanbul aylara göre ortalama satış rakamları.



Şekil 5.25 : Ramazan ayındaki satışlarla diğer ayların kıyaslaması.

Çizelge 5.11'e lag değerlerine baktığımızda en faydalı görünen 4 hafta öncesine ait satış değerleri kullanılabilir.

Çizelge 5.11 : Lag değerleri ile satış rakamlarının korelasyon değerleri.

	SalesCount
Sales	Count
	1.0
D1_Lt	0.8
D2_Lt	0.8
D3_Lt	0.2
D4_Lt	0.9
D5_Lt	0.7
D6_Lt	0.8
Price	-0.4

Çizelge 5.12’de Temp, Max_temp, Min_temp değerlerinin birbiriyle korelasyonları çok yüksek olduğu gözlenmektedir; bu değerlerden en çok satış rakamlarıyla ilişkisi olan temp değeri referans alınmıştır. Buna benzer olarak Lag değerlerinden en çok satış değerini açıklayabilen D4_Lt değeridir. Ayrıca döviz kurundaki değişikliklerin etkisini incelemek için Dolar/TL paritesini temsilen Price değeri kullanılmıştır.

Çizelge 5.12 : Hava durumu değerleri ile satış rakamlarının korelasyonu.

	SalesCount
SalesCount	1.0
temp	-0.6
Max_temp	-0.6
Min_temp	-0.6
snow	0.1
gunes	-0.3

Çoklu lineer analizde, öncelikle korelasyon ve lineer model analiziyle değişkenlerin satış değerlerine etkisi incelendi. İl bazında incelendiğinde sıcaklık değerleri her ilde aynı etkiyi göstermemektedir. Sıcaklık değerleri ve satış rakamlarının korelasyonunun en fazla olduğu il, -0,6 değeriyle İstanbul çıkmıştır. Lineer model analizinde ise, kullanılan sıcaklık, güneşlenme süresi, nem, kar yağışı, dolar paritesi, 4 hafta önceki satış değeri kullanılarak açıklayıcı bir model oluşturulmuştur. Çizelge 5.13’de görüldüğü gibi model, 0,91 R kare değeriyle, satışların yüzde 91’ini açıklayabilmektedir. Çizelge 5.14’de görüldüğü gibi Ramazan ayının olup olmaması (B=-76,9), sıcaklık (B=-4,9) ve 4 hafta önceki satış değeri (B=0,59) istatistiki olarak $p<0,001$ anlamlı, ekstrem hava koşullarını temsil eden kar yağışı (B=-47) ise istatistiki olarak $p<0,05$ anlamlı çıkmıştır. Çoklu lineer analizde üstte değişkenleri direk modele uyguladık ancak aslında değişkenlerin sayısal değerleri etkilerini etkiliyor yani kategorik değişkenlerin de etkisini iyi görebilmek için hepsini normalize etmek gerekir.

Çizelge 5.13 : Modelin tahmin yeterliliği.

Residual standard error	27 on 99 degrees of freedom
Multiple R-squared	0.915
Adjusted R-squared	0.905
F-statistic	88.9 on 12 and 99 DF
p-value	<2e-16

Ramazan'ın etkisi olması gerektiğinden fazla gözüküyor olabilir. Ayrıca Takvimsel etkiyi modele eklemek yanıltıcı olabilir istediğimiz değişkenlerin direk etkisini görmek için model takvimsel değişkenler ve lag degerleri çıkartıp kurulmuştur.

Çizelge 5.14 : Lineer model katsayıları.

	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	379.4249	101.8170	3.73	0.00032	***
ilsimit\$Price	-2.19	2.4	-0.93	0.36	
ilsimit\$Year2015-01-01	5.79	14.7	0.39	0.7	
ilsimit\$Year2016-01-01	-36	19.9	-1.81	0.07	.
ilsimit\$Yearc("2014-01-01",	-39.4	28.8	-1.37	0.17	
ilsimit\$Yearc("2015-01-01",	-14.7	42.1	-0.35	0.73	
ilsimit\$Ramazan	-76.9	10.4	-7.42	4.1e-11	***
ilsimit\$IsNationalHoliday	6.74	19.7	0.34	0.74	
ilsimit\$temp	-4.9	0.8	-6.23	1.1e-08	***
ilsimit\$precip	0.09	0.6	0.15	0.88	
ilsimit\$gunes	20.6	10.8	1.90	0.06	.
ilsimit\$snow_factor	-47.6	21.9	-2.18	0.03	*
ilsimit\$D4_Lt	0.6	0.09	6.54	2.7e-09	***

Çizelge 5.15 incelediğimizde sıcaklık modeli en çok etkileyen değişken. Bunun yanı sıra ramazan ayının olması da ciddi anlamda etkiliyor. Gün ay yıl gibi takvimsel değişkenleri çıkardığımızda görüyoruz ki dolar/tl paritesi de modeli ciddi oranda etkiliyor. Özellikle yıldan yıla satışlar azaldığı için dolar/tl paritesiyle benzer etkiyi yapıyor.

Çizelge 5.15 : Normalize edilmiş değerlerle modelin tekrar kurdulması gerekir.


	Estimate	Std. Error	t value	Pr(> t)	
(Intercept)	0,637	0,130	4,895	0,0000	***
ilsimit_Norm\$Price	-0,265	0,034	-7,87	0,0000	***
ilsimit_Norm\$Ramazan	-0,319	0,032	-10,05	< 2e-16	***
ilsimit_Norm\$IsNationalHoliday	-0,006	0,073	-0,079	0,9373	
ilsimit_Norm\$temp	-0,529	0,058	-9,161	0,0000	***
ilsimit_Norm\$snow_lag1	4,157	3,569	1,165	0,2469	
ilsimit_Norm\$snow_after_factor	-0,130	0,116	-1,125	0,2632	
ilsimit_Norm\$precip	0,166	0,064	2,601	0,0107	*
ilsimit_Norm\$gunes	0,119	0,036	3,300	0,0013	**
ilsimit_Norm\$snow_factor1	-0,185	0,065	-2,872	0,0050	**

Çizelge 5.15’da görüldüğü gibi Ramazan ayının olup olmaması ($B=-0,32$), sıcaklık ($B=-0,53$) ve Dolar/TL paritesi ($B=0,27$) istatistiki olarak $p<0,001$ anlamlı, ekstrem hava koşullarını temsil eden kar yağışı ($B=-0,19$) ve güneşlenme süresi ($B=0,12$) ise istatistiki olarak $p<0,05$ anlamlı çıkmıştır. Çizelge 5.16’de görüldüğü gibi model, 0,79 R kare değeriyle, satışların yüzde 79’unu açıklayabilmektedir.

Çizelge 5.16 : Normalize olmuş değerlerle kurulan modelin R kare değerleri.

Residual standard error	0,102 on 101 degrees of freedom
Multiple R-squared	0.815
Adjusted R-squared	0.7987
F-statistic	49,49 on 9 and 101 DF
p-value	<2e-16

Bu model uygulandıktan sonra yani çoklu lineer regresyon tahmin sonrası grafik Şekil 5.26’da olduğu gibidir.




Şekil 5.26 : MLR ile yukarıda belirlediğimiz değişkenlerle tahmin grafiği.

5.6.2.1 Çok değişkenli sonuçlar

Çoklu lineer analizi sonrası, çok değişkenli modellerle satış tahmin yapılmıştır. Bu tahminlere Çizelge 5.17’e göre ise, en iyi sonuç, 39 RMSE değeriyle MLR yöntemi olmuştur. Grafiks gösterimi ise Şekil 5.27’deki gibidir.

Çizelge 5.17 : Çok değişkenli tahmin sonuçları.

	RMSE	MAE
MLR	39	31
MLR_AR	49	35
ARIMAX	40	29



Şekil 5.27 : Çok değişkenli yöntemlerin hatalarının karşılaştırılması.

6. SONUÇ VE ÖNERİLER

Yapılan ilk analiz olan univariate analizde, zaman serilerindeki tahmin performansları karşılaştırılmıştır. Tek adımlı tahminin sonuçlarına bakıldığında, ETS ve SARIMA modellerinin sırasıyla 36 ve 34 RMSE değerleriyle yapay sinir ağları yöntemlerine yakın sonuç verdiği görülmektedir. Çok adımlı (4 haftalık) tahmin sonuçlarında ise, SARIMA, ETS, Encoder Decoder LSTM ve LSTM yöntemleri ortalama RMSE değerleriyle diğer yöntemlerden daha iyi sonuç vermiştir.

Çoklu lineer analizde, öncelikle korelasyon ve lineer model analiziyle değişkenlerin satış değerlerine etkisi incelendi. İl bazında incelendiğinde sıcaklık değerleri her ilde aynı etkiyi göstermemektedir. Sıcaklık değerleri ve satış rakamlarının korelasyonunun en fazla olduğu il, -0,6 değeriyle İstanbul çıkmıştır. Lineer model analizinde ise, kullanılan sıcaklık, güneşlenme süresi, nem, kar yağışı, dolar paritesi, 4 hafta önceki satış değeri kullanılarak açıklayıcı bir model oluşturulmuştur. Model, 0,79 R kare değeriyle, satışların yüzde 79'unu açıklayabilmektedir. Ramazan ayının olup olmaması ($B=-0,32$), sıcaklık ($B=-0,53$) ve Dolar/TL paritesi ($B=0,27$) istatistiki olarak $p<0,001$ anlamlı, ekstrem hava koşullarını temsil eden kar yağışı ($B=-0,19$) ve güneşlenme süresi ($B=0,12$) ise istatistiki olarak $p<0,05$ anlamlı çıkmıştır.

Çoklu lineer analizi sonrası, çok değişkenli modellerle satış tahmin yapılmıştır. Bu tahminlere göre ise, en iyi sonuç, 39 RMSE değeriyle MLR yöntemi olmuştur.

Sonuçlara baktığımızda zaman serilerinde klasik yöntemlerin iyi sonuçlar verebildiğini görüyoruz. Bununla beraber, zaman serilerinde LSTM yöntemi önerilmesine rağmen tek boyutlu CNN'in de iyi sonuçlar verdiği gözlenmektedir. Ayrıca, çok adımlı tahminde Hibrit derin sinir ağları modellerinin iyi sonuç verdiği ortaya çıkmıştır. Tek adımlı tahminde ise, CNN yönteminin en az LSTM yöntemi kadar iyi sonuç verdiği gözlenmiştir.

Sonraki çalışmalarda, mağaza trafiği ve mağaza satış bilgisinin mevcut olması durumunda, bu değişkenlerin daha zengin ve açıklayıcı modeller oluşturması öngörülebilir. Mağaza satış verileri mevcut olması, sıcaklığın mağaza trafiğine ve

insan davranışına olan etkisinin saptanmasını mümkün olabilirdi. Ayrıca, promosyon bilgisi ile de promosyonların satışlara etkisi ölçülebilirdi. Sonraki çalışmalarda hava sıcaklığının diğer ürünlere etkisi ya da yeterli veri olursa insanların alım tercihlerine etkisi incelenebilir.



KAYNAKLAR

- Lasek, A. C. N. S. J., Cercone, N., & Saunders, J.** (2016). Smart Restaurants: Survey on customer demand and sales forecasting. In *Smart Cities and Homes* (pp. 361-386). Morgan Kaufmann.
- Bohanec, M., Borštnar, M. K., & Robnik-Šikonja, M.** (2017). Explaining machine learning models in sales predictions. *Expert Systems with Applications*, 71, 416-428.
- Abrahart, R. J. & See, L.** (1998). Neural Network vs. ARMA Modelling: Constructing Benchmark Case Studies of River Flow Prediction. In J. Blenc, (Ed.), *GeoComputation '98. Proceedings of the Third International Conference on GeoComputation*, (pp.145-154). United Kingdom : University of Bristol, September 17-19.
- Tian, J., Zhang, Y., & Zhang, C.** (2018). Predicting consumer variety-seeking through weather data analytics. *Electronic Commerce Research and Applications*, 28, 194-207.,
- Tealab, Ahmed.** "Time Series Forecasting using Artificial Neural Networks Methodologies: A Systematic Review." *Future Computing and Informatics Journal* (2018).
- Liu, X., & Ichise, R.** (2017, July). Food sales prediction with meteorological data—a case study of a japanese chain supermarket. In *International Conference on Data Mining and Big Data* (pp. 93-104). Springer, Cham.
- Francis, H., & Kusiak, A.** (2017). Prediction of engine demand with a data-driven approach. *Procedia Computer Science*, 103, 28-35.
- Deb, C., Zhang, F., Yang, J., Lee, S. E., & Shah, K. W.** (2017). A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, 74, 902-924.
- Voyant, Cyril, et al.** "Machine learning methods for solar radiation forecasting: A review." *Renewable Energy* 105 (2017): 569-582.
- Francis, H., & Kusiak, A.** (2017). Prediction of engine demand with a data-driven approach. *Procedia Computer Science*, 103, 28-35.
- Liu, L. M., Bhattacharyya, S., Sclove, S. L., Chen, R., & Lattyak, W. J.** (2001). Data mining on time series: an illustration using fast-food restaurant franchise data. *Computational Statistics & Data Analysis*, 37(4), 455-476.
- Bahng, Y., & Kincade, D. H.** (2012). The relationship between temperature and sales: Sales data analysis of a retailer of branded women's business wear. *International Journal of Retail & Distribution Management*, 40(6), 410-426.

- Ramanathan, U., & Muyltermans, L.** (2010). Identifying demand factors for promotional planning and forecasting: A case of a soft drink company in the UK. *International Journal of Production Economics*, 128(2), 538-545.
- Bozkir, A. S., & Sezer, E. A.** (2011). Predicting food demand in food courts by decision tree approaches. *Procedia Computer Science*, 3, 759-763.
- Doganis, P., Alexandridis, A., Patrinos, P., & Sarimveis, H.** (2006). Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing. *Journal of Food Engineering*, 75(2), 196-204.
- Arunraj, N. S., & Ahrens, D.** (2016). Estimation of non-catastrophic weather impacts for retail industry. *International Journal of Retail & Distribution Management*, 44(7), 731-753.
- Kolassa, S., & Siensen, E.** (2016). Demand forecasting for managers. Business Expert Press.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V.** (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PloS one*, 13(3), e0194889.
- Lasek, A., Cercone, N., & Saunders, J.** (2016). Restaurant sales and customer demand forecasting: Literature survey and categorization of methods. In *Smart City 360°* (pp. 479-491). Springer, Cham.
- Beverton, R. J., & Holt, S. J.** (1957). On the dynamics of exploited fish populations, *Fishery Investigations Series II*, Vol. XIX, Ministry of Agriculture. Fisheries and Food, 1, 957.
- Winters, P. R.** (1960). Forecasting sales by exponentially weighted moving averages. *Management science*, 6(3), 324-342.
- Wong, W. K., & Guo, Z. X.** (2010). A hybrid intelligent model for medium-term sales forecasting in fashion retail supply chains using extreme learning machine and harmony search algorithm. *International Journal of Production Economics*, 128(2), 614-624.
- Aksoy, A., Öztürk, N., & Sucky, E.** (2014). Demand forecasting for apparel manufacturers by using neuro-fuzzy techniques. *Journal of Modelling in Management*, 9(1), 18-35.
- Wu, D. C., Song, H., & Shen, S.** (2017). New developments in tourism and hotel demand modeling and forecasting. *International Journal of Contemporary Hospitality Management*, 29(1), 507-529.
- Xiong, T., Li, C., & Bao, Y.** (2018). Seasonal forecasting of agricultural commodity price using a hybrid STL and ELM method: Evidence from the vegetable market in China. *Neurocomputing*, 275, 2831-2844.
- Liu, H., Mi, X., & Li, Y.** (2018). Smart deep learning based wind speed prediction model using wavelet packet decomposition, convolutional neural network and convolutional long short term memory network. *Energy Conversion and Management*, 166, 120-131.

- Längkvist, M., Karlsson, L., & Loutfi, A.** (2014). A review of unsupervised feature learning and deep learning for time-series modeling. *Pattern Recognition Letters*, 42, 11-24.
- Shabani, S., Yousefi, P., & Naser, G.** (2017). Support vector machines in urban water demand forecasting using phase space reconstruction. *Procedia Engineering*, 186, 537-543.
- Arunraj, N. S., & Ahrens, D.** (2015). A hybrid seasonal autoregressive integrated moving average and quantile regression for daily food sales forecasting. *International Journal of Production Economics*, 170, 321-335.
- Žliobaitė, I., Bakker, J., & Pechenizkiy, M.** (2012). Beating the baseline prediction in food sales: How intelligent an intelligent predictor is?. *Expert Systems with Applications*, 39(1), 806-815.
- Donkor, E. A., Mazzuchi, T. A., Soyer, R., & Alan Roberson, J.** (2012). Urban water demand forecasting: review of methods and models. *Journal of Water Resources Planning and Management*, 140(2), 146-159.
- Witt, S. F., & Witt, C. A.** (1995). Forecasting tourism demand: A review of empirical research. *International Journal of forecasting*, 11(3), 447-475.
- Suganthi, L., & Samuel, A. A.** (2012). Energy models for demand forecasting—A review. *Renewable and sustainable energy reviews*, 16(2), 1223-1240.
- Fildes, R., & Kumar, V.** (2002). Telecommunications demand forecasting—a review. *International Journal of Forecasting*, 18(4), 489-522.
- Nenni, M. E., Giustiniano, L., & Pirolo, L.** (2013). Demand forecasting in the fashion industry: a review. *International Journal of Engineering Business Management*, 5, 37.
- Bertrand, J. L., Brusset, X., & Fortin, M.** (2015). Assessing and hedging the cost of unseasonal weather: Case of the apparel sector. *European Journal of Operational Research*, 244(1), 261-276.
- Ni, Y., & Fan, F.** (2011). A two-stage dynamic sales forecasting model for the fashion retail. *Expert Systems with Applications*, 38(3), 1529-1536.
- Martínez, F., Frías, M. P., Pérez-Godoy, M. D., & Rivera, A. J.** (2018). Dealing with seasonality by narrowing the training set in time series forecasting with kNN. *Expert Systems with Applications*, 103, 38-48.
- Gun Lim, G., Hyun Kim, D., Choi, M., Choi, J. H., & Chang Lee, K.** (2010). An exploratory study of the weather and calendar effects on tourism web site usage. *Online Information Review*, 34(1), 127-144.
- Chen, L. F., & Tsai, C. T.** (2016). Data mining framework based on rough set theory to improve location selection decisions: A case study of a restaurant chain. *Tourism Management*, 53, 197-206.
- Siame-Namini, S., Tavakoli, N., & Namin, A. S.** (2018, December). A Comparison of ARIMA and LSTM in Forecasting Time Series. In *2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA)* (pp. 1394-1401). IEEE.

- Loureiro, A. L. D., Miguéis, V. L., & da Silva, L. F.** (2018). Exploring the use of deep neural networks for sales forecasting in fashion retail. *Decision Support Systems*, 114, 81-93.
- Vengertsev, D.** (2014). Deep learning architecture for univariate time series forecasting. *Cs229*, 3-7.
- Kotu, V., & Deshpande, B.** (2014). *Predictive analytics and data mining: concepts and practice with rapidminer*. Morgan Kaufmann.
- Gardner Jr, E. S., & McKenzie, E. D.** (1985). Forecasting trends in time series. *Management Science*, 31(10), 1237-1246.
- Borovykh, A., Bohte, S., & Oosterlee, C. W.** (2017). Conditional time series forecasting with convolutional neural networks. *arXiv preprint arXiv:1703.04691*.
- Hochreiter, S., & Schmidhuber, J.** (1997). Long short-term memory. *Neural computation*, 9(8), 1735-1780.
- Boone, T., Ganeshan, R., Jain, A., & Sanders, N. R.** (2018). Forecasting sales in the supply chain: Consumer analytics in the big data era. *International Journal of Forecasting*.
- Url-1** <<https://www.becomeafranchise.com/turkiyede-franchising-pazari>>, erişim tarihi 01.04.2019.
- Url-2** <<https://towardsdatascience.com/applied-deep-learning-part-4-convolutional-neural-networks-584bc134c1e2>>, 01.04.2019.
- Url-3** < <http://colah.github.io/posts/2015-08-Understanding-LSTMs/> >, erişim tarihi 01.04.2019
- Url-4** <<http://cs231n.github.io/convolutional-networks/>>, erişim tarihi 01.04.2019
- Url-5** <<http://cs231n.github.io/convolutional-networks/>>, erişim tarihi 01.04.2019

EKLER

EK.A Tek Adımlı Grid Search Sonuçları



Çizelge A. 1 : MA.

0	MAE	MAPE	RMSE	n_train	n_test	n_window
[1, 4, 'mean']	36,13	18,43	52,29	100	12	4
[1, 4, 'median']	36,13	18,43	52,29	100	12	4
[2, 4, 'mean']	59,04	28,49	72,42	100	12	4
[2, 4, 'median']	59,04	28,49	72,42	100	12	4
[3, 4, 'mean']	70,25	33,22	81,82	100	12	4
[4, 4, 'mean']	72,75	34,27	83,98	100	12	4
[11, 4, 'mean']	77,87	36,43	88,44	100	12	4
[5, 4, 'mean']	78,57	36,73	89,07	100	12	4
[7, 4, 'mean']	79,27	37,02	89,68	100	12	4

Çizelge A. 2 : NAIVE.

	MAE	RMSE	MAPE	n_train	n_test
[7, 1, 'median']	38,61	54,59	19,57	100	12
[7, 1, 'mean']	39,85	55,81	20,14	100	12
[4, 1, 'mean']	40,92	56,87	20,64	100	12
[4, 1, 'median']	41,01	56,96	20,68	100	12
[6, 1, 'median']	41,01	56,96	20,68	100	12
[8, 1, 'median']	41,01	56,96	20,68	100	12
[6, 1, 'mean']	41,79	57,77	21,04	100	12
[2, 1, 'mean']	42,07	58,05	21,17	100	12
[2, 1, 'median']	42,07	58,05	21,17	100	12

Çizelge A. 3 : MLP.

0	MAPE	RMSE	MAE
[4, 50, 50, 112, 1]	10,31	34,69	21,43
[4, 50, 50, 100, 1]	10,43	34,96	20,99
[4, 50, 100, 100, 1]	10,68	35,22	22,31
[4, 50, 100, 112, 1]	10,73	35,40	22,25
[12, 50, 150, 100, 1]	12,98	35,56	25,00
[12, 50, 100, 112, 1]	12,23	35,60	24,33
[12, 50, 100, 100, 1]	12,27	35,64	26,02
[4, 50, 150, 100, 1]	11,01	36,18	22,76
[12, 50, 50, 100, 1]	11,29	36,23	23,16
[4, 50, 100, 1, 1]	11,77	36,29	24,80
[4, 50, 150, 112, 1]	10,89	36,34	22,42
[4, 50, 50, 1, 1]	11,40	36,98	23,30
[4, 50, 150, 1, 1]	12,36	37,67	25,20
[12, 50, 150, 112, 1]	12,59	37,86	25,58
[12, 50, 50, 112, 1]	11,40	37,94	23,58
[12, 50, 50, 1, 1]	14,98	40,45	31,49
[12, 50, 100, 1, 1]	15,73	44,57	33,33
[12, 50, 150, 1, 1]	16,17	46,42	32,77

Çizelge A. 4 : CNN.

0	MAE	MAPE	RMSE
[12, 32, 5, 100, 32, 1]	23,65	10,72	34,87
[12, 64, 5, 100, 1, 0]	23,87	11,59	36,38
[12, 32, 5, 100, 10, 1]	24,97	10,90	36,73
[8, 32, 5, 100, 1, 0]	24,56	11,81	36,81
[12, 32, 5, 100, 1, 0]	25,10	11,56	36,88
[8, 32, 5, 100, 10, 1]	25,33	11,05	37,08
[8, 32, 5, 100, 32, 1]	23,67	11,24	37,33
[8, 32, 5, 100, 1, 1]	28,25	13,14	38,66
[8, 32, 5, 100, 10, 0]	28,74	17,96	43,18
[12, 32, 5, 100, 10, 0]	33,23	17,31	45,87
[12, 32, 5, 100, 1, 1]	32,33	15,97	48,23
[8, 32, 5, 100, 32, 0]	35,83	18,05	48,41
[12, 64, 5, 100, 64, 0]	34,96	17,54	48,45
[12, 32, 5, 100, 32, 0]	34,86	17,60	48,86
[12, 64, 5, 100, 100, 0]	35,22	18,00	51,63

Çizelge A. 5 : LSTM.

	MAPE	MAE	RMSE
12, 100, 50, 1, 1	9.911	20,668	35,82
12, 100, 50, 50, 1	12.068	21,966	38,42
12, 100, 50, 200, 0	13.947	25,15415	41,70
12, 100, 50, 1, 0	11.158	25,372	35,53
12, 100, 50, 100, 0	13.494	26,24202	42,56
12, 100, 50, 200, 1	13.302	27,40675	43,60
12, 100, 50, 100, 1	13.286	28,09204	42,48
12, 100, 50, 50, 0	12.786	28,779	41,49

Çizelge A. 6 : SARIMA.

0	MAE	MAPE	RMSE
[(1, 0, 2), (1, 0, 0, 0), 'ct']	21,128	20,61	34,53
[(2, 1, 0), (0, 0, 1, 0), 'ct']	23,65	20,508	35,015
[(1, 1, 2), (1, 0, 0, 0), 't']	23,048	20,691	35,21
[(2, 1, 0), (0, 0, 1, 0), 't']	23,004	20,683	35,267
[(2, 0, 0), (1, 0, 1, 0), 'ct']	24,131	21,378	35,521
[(1, 1, 2), (0, 0, 0, 0), 't']	23,335	20,608	35,58
[(0, 1, 2), (1, 0, 0, 0), 't']	23,359	20,606	35,587
[(1, 0, 1), (1, 0, 1, 0), 'ct']	24,117	21,149	35,663
[(1, 1, 2), (0, 0, 1, 0), 't']	23,335	20,63	35,687
[(2, 1, 2), (0, 0, 1, 0), 't']	23,315	20,719	35,872
[(1, 0, 0), (1, 0, 1, 0), 'ct']	22,44	20,927	36,025
[(1, 0, 0), (0, 0, 0, 0), 'ct']	22,589	20,576	36,037
[(1, 0, 0), (0, 0, 1, 0), 'ct']	23,576	21,149	36,078
[(2, 0, 1), (1, 0, 1, 0), 'ct']	23,215	20,655	36,102

Çizelge A. 7 : ETS.

0	MAE	RMSE	MAPE
['mul', True, None, 4, True, False]	25,02	36,72	11,90
['add', True, None, 4, True, False]	25,18	36,70	11,90
['add', True, None, 4, False, False]	25,18	36,70	11,90
['mul', True, None, 4, False, False]	25,18	36,70	11,81
['mul', False, None, 4, False, True]	25,31	36,63	12,00
['mul', False, None, 4, False, False]	25,40	36,56	11,99
['mul', True, None, 4, True, True]	25,41	36,87	12,09
['mul', False, None, 4, True, False]	25,43	36,49	11,96
['mul', False, None, 4, True, True]	25,46	36,78	12,02
['mul', True, None, 4, False, True]	25,58	36,82	11,99

ÖZGEÇMİŞ

Ad-Soyad : Sezgi ASLANKURT ŞENER
Doğum Tarihi ve Yeri : 02.09.1986 Adana
E-posta : sezgiaslankurt@gmail.com
Telefon : 05347009170

ÖĞRENİM DURUMU:

- **Lisans** : 2010, ITU, Elektrik-Elektronik Fakültesi, Elektronik Mühendisliği Bölümü

MESLEKİ DENEYİM VE ÖDÜLLER:

- 2010-2016 yılları arasında Netaşta çalıştı.
- 2017'den beri Vodafone şirketinde çalışmaktadır.