

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OTOMOTİV DÖKÜM PARÇA TALEP TAHMİNİNİN YAPAY
SİNİR AĞLARI İLE MODELLENMESİ VE ARIMA YÖNTEMİ İLE
KARŞILAŞTIRMALI ANALİZİ

YÜKSEK LİSANS TEZİ

Selinay KAYALI

Endüstri Mühendisliği Anabilim Dalı

ŞUBAT 2024

T.C.
SAKARYA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

OTOMOTİV DÖKÜM PARÇA TALEP TAHMİNİNİN YAPAY
SİNİR AĞLARI İLE MODELLENMESİ VE ARIMA YÖNTEMİ İLE
KARŞILAŞTIRMALI ANALİZİ

YÜKSEK LİSANS TEZİ

Selinay KAYALI

Endüstri Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. Merve CENGİZ TOKLU

ŞUBAT 2024

Selinay KAYALI tarafından hazırlanan “Otomotiv Döküm Parça Talep Tahmininin Yapay Sinir Ağları ile Modellenmesi ve ARIMA Yöntemi ile Karşılaştırmalı Analizi” adlı tez çalışması 01.02.2024 tarihinde aşağıdaki jüri tarafından oy birliği/oy çokluğu ile Sakarya Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı’nda Yüksek Lisans tezi olarak kabul edilmiştir.

Tez Jürisi

Jüri Başkanı :	Dr. Öğr. Üyesi Sena KIR Sakarya Üniversitesi	
Jüri Üyesi :	Doç. Dr. Merve CENGİZ TOKLU Sakarya Üniversitesi	
Jüri Üyesi :	Dr. Öğr. Üyesi Çağatay TEKE Bayburt Üniversitesi	



ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Sakarya Üniversitesi Fen Bilimleri Enstitüsü Lisansüstü Eğitim-Öğretim Yönetmeliğine ve Yükseköğretim Kurumları Bilimsel Araştırma ve Yayın Etiği Yönergesine uygun olarak hazırlamış olduğum “OTOMOTİV DÖKÜM PARÇA TALEP TAHMİNİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ VE ARIMA YÖNTEMİ İLE KARŞILAŞTIRMALI ANALİZİ” başlıklı tezin bana ait, özgün bir çalışma olduğunu; çalışmamın tüm aşamalarında yukarıda belirtilen yönetmelik ve yönergeye uygun davrandığımı, tezin içerdiği yenilik ve sonuçları başka bir yerden almadığımı, tezde kullandığım eserleri usulüne göre kaynak olarak gösterdiğimi, bu tezi başka bir bilim kuruluna akademik amaç ve unvan almak amacıyla vermediğimi ve 20.04.2016 tarihli Resmi Gazete’de yayımlanan Lisansüstü Eğitim ve Öğretim Yönetmeliğinin 9/2 ve 22/2 maddeleri gereğince Sakarya Üniversitesi’nin abonesi olduğu intihal yazılım programı kullanılarak Enstitü tarafından belirlenmiş ölçütlere uygun rapor alındığını, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun ortaya çıkması halinde doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi beyan ederim.

(01/02/2024)

(imza)

Selinay KAYALI





Beni ben yapan her şeye ve herkese...



TEŞEKKÜR

Her durumda yanımda destekçim olan aileme en büyük teşekkürlerimi sunarım. Ayrıca yüksek lisans sınavına zorla götürüp yüksek lisans sürecimde yanımda olup yüksek mühendis olmamı sağlayan Fulya SEZER'e teşekkür ederim. Ve son olarak akademik hayattaki tek idolüm olan gerek özel hayatımda gerek iş hayatımda yol gösterici olup yolumu aydınlatıp tavsiyelerde bulunan, beraber çalıştığım için gurur duyduğum Yüksek Mühendis olmamı sağlayan değerli hocam Merve CENGİZ TOKLU'ya teşekkür ederim.

Selinay KAYALI



İÇİNDEKİLER

Sayfa

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	v
TEŞEKKÜR	ix
İÇİNDEKİLER	xi
KISALTMALAR	xiii
SİMGELER	xv
TABLO LİSTESİ	xvii
ŞEKİL LİSTESİ	xix
ÖZET	xxi
SUMMARY	xxiii
1. GİRİŞ	1
1.1. Literatür Araştırması	3
2. YÖNTEM	11
2.1. Talep Tahmini Yöntemleri	12
2.1.1. Zaman serisi yöntemleri	13
2.1.2. Makine öğrenimi yöntemleri	13
2.1.3. Derin öğrenme yöntemleri	14
2.2. Aykırı Veri Analizi Yöntemleri	14
2.2.1. Box- plot yöntemi	14
2.3. Yapay Sinir Ağları	15
2.3.1. Yapay sinir ağı mimarisi	19
2.3.2. Aktivasyon fonksiyonu	20
2.3.3. Yapay sinir ağı öğrenme yaklaşımları	22
2.3.4. Geri yayılım öğrenme algoritmaları	23
2.4. ARIMA	24
2.5. Hata Analiz Yöntemleri	25
2.5.1. Ortalama mutlak hata (MAE)	26
2.5.2. Ortalama kare hata (MSE)	26
2.5.3. Kök ortalama kare hata (RMSE)	27
2.5.4. R kare analizi (R²)	27
2.5.5. Ortalama mutlak yüzde hata (MAPE)	28
3. UYGULAMA	29
3.1. Döküm Sektörü	30
3.2. Çalışmada Kullanılacak Parçanın Seçilmesi	30
3.3. Satışı Etkileyen Girdilerin Belirlenmesi	30
3.4. Uygulamada Kullanılan Tahmin Yöntemleri	32
3.4.1. Yapay sinir ağı uygulaması	33
3.4.2. ARIMA yöntemi uygulaması	39
3.5. Yapay Sinir Ağı ve ARIMA Uygulama Sonuçları	44
4. SONUÇ VE ÖNERİLER	49
KAYNAKLAR	51
ÖZGEÇMİŞ	59



KISALTMALAR

ACF	: Auto-correlation function
ADF	: Augmented Dickey-Fuller test
AIC	: Akaike information criterion
AR	: Autoregression/Otoregresif
ARIMA	: Autoregressive integrated moving average
EBY	: Enerji Bilgi Yönetimi
GSYH	: Gayri safi yurt içi hasıla
I	: Integrated/Entegre
LOGSIG	: Sigmoid Fonksiyon
LSTM	: Long short-term memory
MA	: Moving Average/Hareketli Ortalama
MAD	: Mutlak ortalama sapma
MAE	: Ortalama mutlak hata
MAPE	: Mutlak ortalama yüzde hata
OSD	: Otomotiv Sanayi Derneği
PACF	: Partial auto-correlation function
RMSE	: Kök ortalama kare hata
SIK	: Çelik Sektörü Bilgisi
TANSIG	: Hiperbolik tanjant fonksiyonu
TCMB	: Türkiye Cumhuriyeti Merkez Bankası
TEİAŞ	: Türkiye Elektrik İletim A.Ş.
TRAINCGB	: Conjugate gradient polak-ribiere algoritması
TRAINCGF	: Conjugate gradient fletcher reeves algoritması
TRAINCGP	: Conjugate gradient powell-beale algoritması
TRAINGD	: Gradient descent algoritması
TRAINGDA	: Gradient descent with adaptive learning rate algoritması
TRAINGDX	: Gradient descent with momentum algoritması
TRAINLM	: Levenberg-marquardt algoritması
TRAINSGB	: Scaled conjugate gradient algoritması
TÜDOKSAD	: Türkiye Döküm Sanayicileri Derneği

TÜİK : Türkiye İstatistik Kurumu
YSA : Yapay sinir ağı



SİMGELER

X_n	: Girdi
w_n	: Ağırlık
Σ	: Toplama fonksiyonu
$f(x)$	: Aktivasyon fonksiyonu
Q	: Eşik değeri
p	: Otoregresif
d	: Fark sayısı
q	: Hareketli ortalama
$\emptyset_p$	: Gecikmeli değerlerin şimdiki değerle ilişkisi
Δ	: Fark alma
ε_t	: Hata terimi
$\emptyset_q$	: Gözlem değeri
n	: Gözlem sayısı
x_i	: Gerçek değer
x	: Tahmin değeri
R^2	: R Kare
SSR	: Hata Kareleri Toplamı
SST	: Toplam Kareler Toplamı



TABLO LİSTESİ

Sayfa

Tablo 2.1. Yapay sinir ağı ve biyolojik sinir hücresi elemanları (Demirci, 2015)....	18
Tablo 3.1. Karşılaştırma yapmak için kullanılan öğrenme algoritmaları tablosu	33
Tablo 3.2. Belirlenen katman ve nöron sayıları	35
Tablo 3.3. Test parametreleri	41
Tablo 3.4. ADF test sonuçları	41
Tablo 3.5. Fark alınmış serinin test parametreleri	43
Tablo 3.6. Fark alınmış seri ADF test sonucu	43
Tablo 3.7. ARIMA yöntemi için önerilen modeller	44
Tablo 3.8. Ortalama mutlak hata (MAE) analizine göre en iyi üç yapay sinir ağı....	44
Tablo 3.9. Ortalama kare hata (MSE) analizine göre en iyi üç yapay sinir ağı.....	45
Tablo 3.10. Kök ortalama kare hata (RMSE) analizine göre en iyi üç yapay sinir ağı	45
Tablo 3.11. R Kare analizine göre en iyi üç yapay sinir ağı	45
Tablo 3.12. Mutlak ortalama yüzde hata (MAPE) analizine göre en iyi üç yapay sinir ağı.....	46
Tablo 3.13. Yapay sinir ağı ve arıma yöntemlerinin R Kare sonuçları	46



ŞEKİL LİSTESİ

Sayfa

Şekil 1.1. Döküm Operasyonları.....	1
Şekil 1.2.Kalıcı Kalıba Döküm Yöntemleri (Baş, 2022)	2
Şekil 1.3.Harcanan Kalıba Döküm Yöntemleri (Baş, 2022)	2
Şekil 2.1.Tahmin aşamaları (Ecemiş, 2022)	11
Şekil 2.2.Tahmin yöntemleri.....	13
Şekil 2.3. Kutu grafiği görselleştirmesi (Keskin vd., 2019)	15
Şekil 2.4. Yapay sinir ağı yapısı	16
Şekil 2.5. Biyolojik sinir hücresi (Koç vd., 2004)	17
Şekil 2.6. Yapay sinir ağı matematiksel yapısı (Karahana, 2011).....	18
Şekil 2.7.İleri beslemeli yapay sinir ağı (Saatçioğlu & Özçakar, 2016).....	19
Şekil 2.8.Geri beslemeli yapay sinir ağı (Saatçioğlu & Özçakar, 2016)	20
Şekil 2.9. Doğrusal fonksiyon grafiği (Uzun, 2019).....	20
Şekil 2.10.Hiperbolik tanjant fonksiyon grafiği (Uzun, 2019)	21
Şekil 2.11. Sigmoid fonksiyon grafiği (Uzun, 2019).....	21
Şekil 2.12. Basamak fonksiyon grafiği (Uzun, 2019).....	22
Şekil 3.1. Uygulamanın akış planı	29
Şekil 3.2. SPSS Box-Plot analiz sonucu	34
Şekil 3.3. Ağ tasarımı	36
Şekil 3.4. 2 katman 10 nöron traincgb yapay sinir ağı modeli	36
Şekil 3.5.Yapay sinir ağı eğitim bilgileri	37
Şekil 3.6. Eğitim, doğrulama ve test regresyon grafikleri	38
Şekil 3.7. Epoch MSE Grafiği	38
Şekil 3.8. Satış verileri zaman serisi grafiği	40
Şekil 3.9. ACF grafiği.....	40
Şekil 3.10. PACF grafiği.....	41
Şekil 3.11. 1 Fark alma işlemi yapılmış zaman serisi grafiği	42
Şekil 3.12. Fark alınmış ACF grafiği.....	42
Şekil 3.13. Fark alınmış PACF grafiği	43
Şekil 3.14. Gerçekleşen ve Tahmin Edilen Satış Değerleri	47



OTOMOTİV DÖKÜM PARÇA TALEP TAHMİNİNİN YAPAY SİNİR AĞLARI İLE MODELLENMESİ VE ARIMA YÖNTEMİ İLE KARŞILAŞTIRMALI ANALİZİ

ÖZET

Şirketler kar edebilmek, sürekliliğini korumak ve büyümek için bazı politikalar uygularlar. Bu politikalara stok yönetimi, üretim planlaması, tedarik zinciri yönetimi ve maliyet yönetimi örnek verilebilir. Uygulanan bu politikaların temelini talep tahmini oluşturur. Otomotiv sektörü geçen her günde teknolojik gelişmeler ile daha da gelişmektedir. Otomotiv sektörünün gelişmesi uygulanan talep tahmini yöntemlerinin de gelişmesi gerektirdiğini ortaya çıkarmıştır. Döküm sektöründe faaliyet gösterip otomotiv sektörünün en önemli tedarikçilerinden birisi olan firmada müşteri ihtiyaçlarını karşılamak ve üretimi yönlendirmek için teknoloji ve üretimi birleştiren şirket için yeni bir talep tahmini yöntemi olan bu çalışma yapılmıştır. Döküm sektörü çok fazla girdiye, üretim olarak dar boğaza, yüksek üretim çeşitliliğine sahiptir. Hem üretim çeşitliliğini hem de kapasite kısıtlarını aynı anda yönetmek ayrıca müşteri beklentilerini tam zamanında karşılamak oldukça zordur. Bu zorluğun önüne geçmekte talep tahmini önemli bir araçtır. Literatürde cam sektörü, ekonomik kurlar, enerji harcamaları, giyim sektörü, beyaz eşya sektörü, yiyecek içecek tüketimleri, otomotiv satışları, demir çelik sektörleri gibi farklı çalışma alanlarında talep tahmini çalışmaları yapılmıştır. Yapılan talep tahmini çalışmalarında yapay sinir ağı, makine öğrenmesi, zaman serisi yöntemleri, istatistiksel yöntemler gibi farklı talep tahmini yöntemleri kullanılmıştır. Bu çalışmada yapay sinir ağının farklı katman sayıları, farklı nöron sayıları ve farklı öğrenme algoritmaları kullanılarak talep tahmini yapılmış, ARIMA yöntemiyle karşılaştırılarak tahmin performansı en iyi talep tahmini yöntemi ve modeli belirlenmiştir. Yapay sinir ağı (YSA) tahminlerinin tahmin performansları ortalama mutlak hata (MAE), R Kare, kök ortalama kare hata (RMSE), mutlak ortalama yüzde hata (MAPE) analizleri ile karşılaştırılmıştır. En iyi yapay sinir ağına R Kare analizine göre karar verilmiştir. Yapay sinir ağı yönteminin sonuçları ARIMA yönteminin sonuçlarıyla karşılaştırılmıştır. ARIMA modellerinin tahmin performansları Akaike Bilgi Kriteri kullanılarak karşılaştırılmıştır. Seçilen parçanın satışını etkileyen kriterler hem uzman görüşleri alınarak hem de literatür taraması yapılarak kamyon üretim adeti, elektrik birim fiyatı, Euro kuru, yurtiçi üretici fiyat endeksi, genel tüketici fiyat endeksi, brent petrol varil fiyatı, hurda fiyatları, pik fiyatları ve gayri safi yurt içi hasıla olarak belirlenmiştir. Çıktı olarak ise parça aile grubuna ait satış adetleri kullanılmıştır. Çalışmada kullanılan veri ise girdi ve çıktı kriterlerine ait 2017 ve 2022 yılları arasındaki aylık verileridir. Yapay sinir ağı yöntemiyle yapılan talep tahmini çalışmalarından R Kare hata analiz yöntemine göre en iyi tahmin performansına sahip çalışma traincgb öğrenme algoritmali, 2 katman 10 nöron, tansig aktivasyon fonksiyonlu yapay sinir ağı modeli olduğu sonucuna ulaşılmıştır. Ayrıca yapay sinir ağı yöntemiyle zaman serisi analizi yöntem sonucunu karşılaştırmak için satış verilerine ARIMA yöntemi uygulanmıştır. ARIMA modelleri arasından Akaike Bilgi Kriteri değeri baz alınarak en iyi ARIMA modeli ARIMA (1,1,1) seçilmiştir. Yapay sinir ağı ile ARIMA (1,1,1) modeli R Kare hata analiz

yöntemiyle karşılaştırılarak yapay sinir ağı modelinin tahmin performansının ARIMA modelinden daha yüksek olduğu sonucuna ulaşılmıştır.



MODELING AND AUTOMOTIVE CASTING PART DEMAND FORECASTING WITH ARTIFICIAL NEURAL NETWORKS AND COMPARATIVE ANALYSIS WITH ARIMA METHOD

SUMMARY

Companies implement specific policies to make profits, maintain continuity, and grow. These policies include inventory management, production planning, supply chain management, and cost management. Demand forecasting forms the basis of these policies. The automotive industry is developing more and more with technological developments every day. The development of the automotive industry has revealed that the applied demand forecasting methods also require development. This study, a new demand forecasting method, was conducted to meet customer needs and direct production in a company that operates in the casting industry and is one of the most important automotive industry suppliers. For the study, the critical parts, which have uncertain customer demand, create a bottleneck in production, and fill the capacities, were determined by taking expert opinions. The production stages of the part can be summarized as follows: First, a mold suitable for the desired shape is prepared. At the same time, while the metal suitable for the intended use of the part is prepared in the melting furnaces, special cores are produced to create cavities inside the part. After preparing the mold, metal, and core, the sand mold casting method creates the part. However, at this stage, the production of the part has been completed, but its operations still need to be completed. The part is cleaned of sand and made to meet customer requirements. The part can then be shipped to the customer. While the casting industry is environmentally friendly by ensuring the reuse of recyclable materials, it is advantageous in reducing costs in mass production and the sensitivity of the parts. The casting industry is a sector that feeds the automotive industry in a wide range. The casting method produces engine blocks, cylinder heads, transmission, suspension, body, brake, and clutch parts used in the automotive industry. The casting industry has much input. Additionally, the variety of parts is very high. This causes bottlenecks in production. It is complicated to manage production diversity and capacity constraints simultaneously and meet customer expectations on time. Demand forecasting is an essential tool in avoiding this difficulty. A high forecast performance of the demand forecast result enables the company to get ahead of its competitors, develop, grow, and become trusted by customers.

When the literature is examined, it has been observed that demand forecasting studies have been carried out in different fields of study, such as the glass sector, economic exchange rates, energy expenditures, clothing sector, white goods sector, food and beverage consumption, automotive sales, and iron and steel sectors. Demand forecasting methods such as artificial neural networks, machine learning, time series analysis, and statistical methods have been used in demand forecasting studies. By comparing the forecast performances of the used demand forecasting methods with each other, the forecast method with the best forecast performance was selected. Each

of the studies contributed to the literature by using different inputs, different data, and different methods.

In this study, the artificial neural network method, which is frequently used in the literature, was used. The artificial neural network was created inspired by the working structure of the human brain. It is generally used to make predictions, detect complex data patterns, analyze data, and voice recognition. In order to carry out the study's artificial neural network application, the criteria affecting the demand for the part were determined by first obtaining expert opinions and conducting a literature review. The determined criteria are truck production quantity, electricity unit price, Euro exchange rate, domestic producer price index, general consumer price index, Brent oil barrel price, scrap prices, peak prices, and gross domestic product. The output of the artificial neural network is the total sales units of the part family group. The data for the determined criteria are monthly data between 2017 and 2022.

Data was collected from various sources to create inputs within the scope of the study. Before taking action on the data, it is necessary to analyze the data. Because there is a possibility of discrete data among the data, having such data in the data set reduces the study's accuracy. In order to analyze with appropriate data, outlier data analysis was performed with Box-Plot analysis, which is a data separation method, and outlier data were removed from the data set. After ensuring the reliability of the data, the data was normalized. The artificial neural network application created models with tansig and logsig activation functions. The prediction performance of both tansig and logsig activation functions was compared. The data that had to be defined in MATLAB was normalized to compare the prediction performances of these two activation functions. While the data was defined in MATLAB, no separate data was divided into learning, testing, and verification. The study was conducted using the random selection feature of MATLAB.

MATLAB software separated the data as training, testing, and validation at 70%-15%-15%. After the data was defined, models with different layers and neuron numbers were created, including eight different learning algorithms: trainlm, traincgf, traincgb, trainingdx, traincgp, trainscg, trainingda, trainingd, which are included in the feedforward backpropagation algorithm, which is different from other studies in the literature. Predictive values were obtained by training the created models in MATLAB. In the literature, the prediction performances of artificial neural network models have been compared with mean absolute error (MAE), R Square, root mean square error (RMSE), and mean absolute percentage error (MAPE) analyses. In the study, analysis was made for all error analysis methods used in the literature. However, in the study, only the three models with the best prediction performance of the error analysis methods were shown. To determine the best artificial neural network model, based on the R Square error analysis method, one of the error analysis methods, it was concluded that it was an artificial neural network model with a traincgb learning algorithm, two layers, ten neurons, tansig activation function.

After the artificial neural network application, ANN's forecast performance was compared with other demand forecasting methods used in the literature. For this, the ARIMA, a time series analysis method, was applied. ARIMA method is a statistical method used in time series analysis. It consists of AR-I-MA components. AR stands for autoregression, I stands for integration, and MA stands for moving average. These three components are brought together and used to predict the future. Parameters are determined by statistical methods to minimize error. The ARIMA method is used in

many areas, such as weather forecasts, market research forecasts, and epidemic analyses. There are advantages and disadvantages to using the ARIMA method. It has many uses, such as economy, finance, and health. When the components are well adjusted, it provides the advantages of forecasting competence in short and medium-term forecasts, flexibility in different models, and accurate evaluation of the results since it is based on statistical theories. When there is not enough data, disadvantages arise, such as being unable to make accurate predictions at low frequencies, making complex-level predictions, and requiring expertise to determine the correct parameters. Since ARIMA is applied to stationary series, it is necessary to check whether the sales data are stationary. Stationarity means that there are no sudden increases or decreases in the series. It is understood from the time series, ACF, and PACF graphs that the series is stationary. At the same time, the Augmented Dickey-Fuller test is performed to check the stationarity of the series. Sales data are transferred to MATLAB, and data are defined for the ARIMA method through the econometric models toolbox in MATLAB. The stationarity of the series is checked by drawing time series, ACF, and PACF graphs. It can be seen from the graphs that the series is not stationary. However, the Augmented Dickey-Fuller test is performed to prove that it is not numerically stationary. As a result of the test, when the test statistic is greater than the critical value, it is clear that the series is not stationary. A difference operation is performed to bring the non-stationary series to stationary form. It was determined as $I=1$ by differencing. It is necessary to check the stationarity of the different series. The time series graph, ACF graph, and PACF graph of the differenced series were drawn in MATLAB. It can be seen from the graphs that the series has become stationary. However, the Augmented Dickey-Fuller test is used to prove stationarity numerically. According to the test result, it was determined that the test statistic was less than the critical value. With this result, it has been confirmed that the series has become stationary, and the AR-I-MA model has $I = 1$. After the I value was finalized as 1, different models were proposed for AR and MA values. Among the proposed models, the value that controls the quality and complexity of the model by minimizing the error is the Akaike Information Criterion value. According to the Akaike Information Criterion value, the ARIMA (1,1,1) model had the highest prediction performance among other ARIMA models. R Square error analysis method was used to compare the prediction performances of the ARIMA model with the highest prediction performance and the artificial neural network model.

The artificial neural network model with a traincgb learning algorithm, two layers, ten neurons, tansig activation function, which was determined to have the highest prediction performance by the artificial neural network method, was compared with the ARIMA (1,1,1) model using R Square analysis. As a result of the comparison, it was concluded that the prediction performance of the artificial neural network model is better than the ARIMA (1,1,1) model. When the estimated sales values of the artificial neural network model and the actual sales values are compared on the graph, it is seen that the prediction performance is very high. A new demand forecasting method was developed for the business in response to the developing automotive industry, and a comparative demand forecasting analysis study was conducted for the foundry industry, which is not available in the literature. This study can be applied to different parts of the business to determine accurate demand forecasting methods. In addition, different data can be developed and expanded with different layers, neurons, activation functions, and learning algorithms to be used in capacity adjustments.



1. GİRİŞ

Talep tahmini şirketlere yol gösterdiği için önemli bir konumdur. Talep tahmini ile geleceğe yönelik aksiyonlar alınarak müşteri ihtiyaçları tam zamanında karşılanabilir. Müşteri beklentilerinin tam zamanında karşılanması şirketlere rekabet etme avantajı sağlar. Bu çalışmada döküm yapılan bir işletmede üretim olarak dar boğaz oluşturup müşteride talebinde dalgalanmalar görülen bir parça aile grubu için yapay sinir ağı ve ARIMA yöntemi uygulanarak talep tahmini çalışması yapılmıştır.

Metallerin şekillendirilmesi ve işlenmesi, yüzyıllardır kullanılan dökümcülük yöntemi sayesinde, endüstrinin en önemli dallarından biri olmuştur. Ağır sanayi ekipmanları, tarım ve gemi makineleri, kuyumculuk gibi farklı alanlarda döküm yöntemiyle üretilen malzemeler yaygın bir şekilde kullanılmaktadır (Taş, 2020).


Döküm operasyonları Şekil 1.1’de görülen ergitme, kalıplama, maça, tamamlama ve işleme olarak beş farklı işlemten geçerek tamamlanmaktadır.




Şekil 1.1. Döküm Operasyonları

Madenin ark ocaklarında elektrik enerjisiyle eritilmesi işlemine ergitme denilmektedir. Döküm operasyonları ergitme işlemiyle başlar. Parçaya ait kalıp ve maça hazırlanır. Kalıbın içerisine maça yerleştirildikten sonra ergitilmiş metal kalıba dökülerek döküm süreci gerçekleşmiş olur. Fakat parça için döküm operasyonları tamamlanmamıştır. Parçanın kumdan ayrılıp temizlenmesi işlemleri parçanın tamamlama sürecini oluşturur. Müşteri talebine göre işleme süreciyle parça sevke hazır duruma gelir.

Döküm yöntemleri kalıcı kalıba ve harcanan kalıba döküm yöntemi olarak ikiye ayrılmaktadır. Kalıcı kalıba döküm yöntemleri Şekil 1.2’de, harcanan kalıba döküm yöntemleri Şekil 1.3’de görüldüğü gibidir (Baş, 2022).



Şekil 1.2.Kalıcı Kalıba Döküm Yöntemleri (Baş, 2022)



Şekil 1.3. Harcanan Kalıba Döküm Yöntemleri (Baş, 2022)

Çalışmanın yapıldığı işletmede kum kalıba döküm yapılmaktadır. Kum kalıba döküm yöntemi harcanan kalıba döküm yöntemleri içerisinde bulunmaktadır. Kum kalıba döküm yöntemi günümüz endüstrisinde özellikle otomotiv parçaları üretiminde tercih edilen bir döküm yöntemidir. Kum kalıba döküm yöntemiyle yüksek kalite de parçaların üretimi gerçekleşir. Ergitilmiş sıvı madenin kalıp içerisine dökülüp

katılaşmasıyla parça üretimi gerçekleşir. Oluşan parça kalıptan çıkarılarak döküm parça olarak adlandırılır (Baş, 2022). Dökümün tercih edilmesi çeşitli avantajlar sağlar. Bu avantajlara örnek verilirse karmaşık parça geometrileri kolaylıkla oluşturulabilir. Bazı parçalara kesin şekiller verilirken bazı parçalar net şekle yakın sonuçlar elde edilir. Döküm ile hem büyük hem küçük parçalar üretilebilir. Döküm yöntemleri seri üretime elverişlidir (Şentürk, 2016). Döküm yönteminin zayıflıkları mevcuttur. Tanecik yapısının homojen dağılmaması gibi mekanik özelliklerde sınırlamalar, ince kesitlerin elde edilmesinde zorluk yaşanması, belirli yöntemlerde boyutsal doğruluk ve yüzey kalitesi düşük olabilirken, ergimiş metalin iş güvenliği endişeleri ve çevresel etkileri dökümün zayıf yönlerine örnek olarak verilebilir (Şentürk, 2016).

Bu çalışmada 2017 ve 2022 yılları arasındaki aylık veriler baz alınarak yapay sinir ağının farklı aktivasyon fonksiyonları farklı öğrenme algoritmaları kullanılarak talep tahmini çalışması yapılmıştır. Ayrıca seçilen parça için 2017 ve 2022 yılları arasındaki satış adetleri baz alınarak ARIMA yöntemiyle de talep tahmini çalışması yapılmıştır. İki farklı yöntemle yapılan talep tahminleri karşılaştırılmış ve yapay sinir ağı yöntemi modelinin tahmin performansının gerçek verilere çok yakın olduğu görülmüştür. Yapılan çalışmanın gerçeğe yakınlığı sebebiyle işletme açısından kullanılabilir bir talep tahmini çalışması olduğu belirlenmiştir. Ayrıca çalışma hem döküm sektöründe yapılması hem de yapay sinir ağının farklı aktivasyon fonksiyonları ve farklı öğrenme algoritmaları kullanılması yönüyle literatüre katkı sağlamıştır.

1.1. Literatür Araştırması

Bu bölümde konuyla ilgili literatür araştırması yapılmıştır. Literatür araştırması iki aşamada ele alınmıştır. Birinci aşamayı literatürdeki otomotiv sektörü talep tahmini çalışmaları oluşturmaktadır. Literatür araştırmasının ikinci aşamasını ise talep tahmini karşılaştırmalı analiz çalışmaları oluşturmaktadır.

Literatür araştırmasının ilk aşamasında otomotiv sektörü talep tahmini çalışmaları incelenmiştir. Eken ve Çiçek (2009), 2007 yıl sonu otomobil satışlarının en yüksek olduğu İstanbul ilini baz alarak kredilerle otomotiv sektörü araçlarına dair anket çalışması yapmışlar kredi artışıyla otomotiv alış artışı olduğu sonucuna ulaşmışlardır. Ayrıca Akgül (2010), reel faiz, ortalama enflasyon, gayri safi yurtiçi hasıla, tüketici endeksi vb. bilgileri baz alarak ilişkisel tarama yöntemiyle otomobil sektörü için çeşitli

tahmin çalışmaları yapmıştır. Erciş (2010), Erzurum ili için otomotiv satan bayilerin yatırım miktarı, fiziksel büyüklük, yıllık işletme giderleri vb. girdi verilerini baz alıp veri zarflama analizi yöntemiyle performans düzeylerini dikkate alıp verimlilik dereceleri belirlemiş, en etkili girdinin yatırım maliyetleri olduğu sonucuna ulaşmıştır. Yazıcıoğlu (2010), otomobil talep tahmini çalışması yapabilmek amacıyla otomobil satışını etkileyen tüketici fiyat endeksi, toptan eşya fiyat endeksi, işsizlik oranı, Türkiye'deki otomobil ihracatı, Türkiye'deki otomobil ithalatı, dolar kuru vb. etmenlerine ait verileri baz alarak yapay sinir ağı ve regresyon analizi yöntemleriyle talep tahmini çalışması yapmış YSA tahmin hatasının regresyon analizi yöntemine göre daha az olduğunu ortaya koymuştur. Wirotcheewan vd. (2011), Tayland'ın otomobil parça ihracatını tahmin etmek amacıyla Tayland'ın en fazla ihracat yaptığı 5 ülkeyi seçerek her biri için ayrı zaman serisi tahmin modeli ve yapay sinir ağı yöntemi kullanarak tahmin çalışması yapmışlardır. Yapılan çalışmanın tahmin performansını ortalama mutlak hata (MAE), ortalama mutlak yüzde hata (MAPE), kök ortalama kare hata (RMSE), ortalama hata kareleri (MSE), analizlerini yapıp MAPE analizi baz alarak YSA Japonya, Almanya, Endonezya için Trendle Üstel Düzleşme yöntemi Çin için doğru sonuç verirken Güney Kore için hata oranı yüksek geldiği için doğru tahmin modeli yok sonucuna ulaşmışlardır. Tahmin çalışması sonuçlarına göre doğrusal programlama ile de maksimum kar elde etmek için en uygun miktarı belirlemişlerdir. Karaatlı vd. (2012), yeni otomobil satışlarının tahminini gayrisafi yurtiçi hasıla, reel kesim güven endeksi, tüketim harcamaları, yatırım harcamaları, otomobil satış adetleri vb. baz alarak Yapay Sinir Ağı yöntemi kullanıp tahmin çalışması yapmışlardır. Gerçek değerler ile tahmin değerlerini MSE, RMSE ve MAPE analizlerine göre karşılaştırıp birbirine çok yakın olduğu sonucuna ulaşmışlardır. Hülsmann vd. (2012), Alman ve ABD otomobil piyasası tahmini yapmak için dışsal ekonomik göstergelerden Alman için DAX ve IFO endeksleri, ABD pazarı için Dow Jones ve BCI endeksleri, yeni araba kayıtları, gayri safi yurtiçi hasıla, kişisel gelir vb. verilerini baz alarak zaman serisi analizi ve veri madenciliği algoritmaları kullanıp tahmin çalışması yapmışlardır. Yapılan çalışmanın sonuçlarını MAPE analiziyle karşılaştırıp en uygun yöntemin karar ağaçları olduğu sonucuna ulaşmışlardır. Kuvvetli vd. (2015), Türkiye'deki araç satışı için geçmiş satış verileri, taşıt kredisi faiz oranı, CO2 emisyonu, yakıt tüketim miktarı vb. ekonomik ve çevresel girdileri baz alarak ileri beslemeli yapay sinir ağı ile lineer regresyon yöntemi kullanarak tahmin çalışması yapmışlardır. Yapılan çalışmanın sonuçlarını regresyon analizi ve MSE ile

karşılaştırıp yapay sinir ağının tahmin performansının daha iyi olduğu sonucuna ulaşmışlardır. Akyurt (2015), yerli otomobil satışı serinin özellikleri ve satış adetleri göz önüne alarak geri yayılım algoritmasıyla eğitilmiş ileri beslemeli yapay sinir ağı modeli kullanıp talep tahmin çalışması yapmış yapay sinir ağı modellerini MSE ve MAPE analizleriyle karşılaştırarak yapay sinir ağı modelinin talep tahmini açısından uygulanabilir olduğunu ortaya koymuştur. Matsumoto ve Ikeda (2015), otomotiv parçalarının yeniden üretimini tahmin etmek için bir otomotiv parçasına ait yeniden üretim adetleri baz alarak zaman serileri analizlerinden üstel düzeltme yöntemi kullanıp talep tahmini çalışması yapmışlardır. Vahabi vd. (2016), otomotiv firmalarından bir tanesinde satış verileri, kişi başına düşen gelir, enflasyon oranı, konut, döviz kuru, ithalat oranı, kredi faiz oranı vb. girdileri baz alarak ANFİS ve genetik algoritmayı birleştirerek tahmin çalışması yapıp RMSE ve R Kare analizi aracılığıyla yapay sinir ağı yöntemiyle karşılaştırmışlar ve ANFİS genetik algoritma birleştirilerek yapılan tahminin daha doğru sonuçlar verdiğine ulaşmışlardır. Benzer şekilde Sarı (2016), motor yataklarının satış tahminini yapmak için dolar kuru, GSYH, araç parkı sayısı, üretilen araç sayısı vb. verileri baz alarak regresyon analizi ve zaman serileri analizi kullanılarak tahmin çalışması yapmış MAD, MSE ve MAPE analizleri kullanarak yapay sinir ağının gerçeğe daha yakın sonuç verdiğine ulaşmıştır. Öztekin (2016), otomobil sektörünün Türkiye için otomobil reel fiyatları, tüketici güven endeksi, nüfus miktarı vb. baz alarak EKK yöntemi ile tahmin edip determinasyon katsayısı, t testi, f testi ve Durbin-Watson testleri yaparak gerçekliğini ortaya koymuştur. Ayrıca Yayar ve Yılmaz (2017), ikinci el otomotiv sektöründe otomotiv talep fiyatını etkileyen renk, yakıt, marka, km, vites, motor, beygir, model vb. özelliklerine ait değerleri baz alarak T83 bölgesi için regresyon analizi yöntemiyle ikinci el otomotiv talep fiyatının regresyon analizi yöntemiyle tahmini yapıp en düşük fiyatın Amasya’da en yüksek fiyatın Samsun’da olduğu sonucuna ulaşmıştır. Işık vd. (2017), Türkiye için ithal otomobil satışları ve döviz kuru verilerini baz alarak Tam Değiştirilmiş En Küçük Kareler, Kanonik Eş bütünleşme Regresyonu ve Dinamik En Küçük Kareler yöntemleriyle satışların döviz kurundan etkilendiği sonucuna ulaşmışlardır. Özçift (2018), bir otomotiv firması için yedek parça satış adetlerini baz alarak bulanık kümeleme algoritmaları kullanıp farklı talep tahmini modelleri önermiş AMAPE modeli daha verimli sonuç vermiştir. Benzer şekilde Yanık (2019), iş makineleri yedek parça üreten bir işletmede geçmiş yıllara ait satış adetleri, dünyada satılan iş makinası sayısı, aylık etki oranı, yıllara ve aylara göre dolar kuru verilerini

baz alarak yapay sinir ağı ve regresyon analizi yöntemiyle talep tahmini çalışması yapmış MAPE ve R Kare analiziyle yapay sinir ağı yönteminin daha iyi sonuçlar verdiğini ortaya koymuştur. Benzer şekilde Karakaş (2019), aylık otomotiv sanayi ihracat geliri verilerini baz alarak ARIMA yöntemiyle tahmin çalışması yapmış MAPE sonuçlarına göre gerçek verilere yakınlığı ile doğruluğu kanıtlamıştır. Benzer şekilde Arsy (2021), bir otomobilin Endonezya’da satış tahmini yapmak için satış verilerini baz alıp gri sistem yaklaşımı, doğrusal regresyon, üstel regresyon ve üstel üçlü düzeltme tekniği karşılaştırmalı analizi yapmıştır. Yapmış olduğu talep tahmini sonuçlarının tahmin performansını MAPE analizine göre karşılaştırmış gri modelin en doğru tahmini yaptığı sonucuna ulaşmıştır. Benzer şekilde Rožanec vd. (2021) otomotiv sektöründe talep tahmini yapmak için ham petrol fiyatı, GSYİH, dünya çapında işsizlik oranı, satın alma yöneticileri endeksi, bakır fiyatı ve araba satışları verilerini baz alarak temel, istatistiksel ve makine öğrenimi algoritmaları ile toplamda 21 tahmin tekniği ile tahmin yapıp R Kare ve MAE ile karşılaştırma yaparak makine öğrenimi algoritmalarının daha iyi sonuç verdiğine ulaşmışlardır. Benzer şekilde Eşidir vd. (2022), Türkiye’de aylık sıfır km otomobil satışlarını tahmin etmek için aylık otomobil ihracatı, aylık otomobil ithalatı, dolar kuru, aylık Türkiye ihracatı, aylık Türkiye ithalatı verilerini baz alarak satış tahmini yapıp MSE, MAPE analizlerine göre karşılaştırarak MAPE sonucuna göre ARIMA’nın YSA’dan daha iyi sonuç verdiğine ulaşmışlardır. Benzer şekilde Yurtsever (2022), otomobil satış tahmini yapmak için otomobil satış verileri, ham petrol fiyatı, işsizlik oranı vb. ekonomik göstergeleri baz alarak LSTM modelleri ile tahmin çalışması yapmıştır. Tahmin performansını MAPE ve RMSE değerlendirmiştir.

Literatür araştırmasının ikinci aşamasını oluşturan talep tahmini karşılaştırmalı analiz çalışmaları bu kısımda detaylı olarak incelenmiştir. Karahan (2011), Malatya ili kuru kayısı ürününe ait ihracat talep tahmini yapmak için dolar kuru, kayısı ihracat fiyat ortalaması, ihracat yapılan ülke sayısı, mevsimsel etki oranı verileri baz alarak yapay sinir ağı ve ARIMA yöntemini kullanarak gelecek dönem kayısı talepleri için tahmin çalışması yapmıştır. Yapılan tahmin sonuçları R Kare, MSE ve MAPE analizleriyle karşılaştırıp yapay sinir ağının daha güvenilir olduğu sonucuna ulaşmıştır. Benzer şekilde Milenkovic vd. (2012), kent içi raylı ulaşımın yolcu talep tahmini yapmak için raylı ulaşımına ait geçmiş verileri baz alarak ARIMA ve ANFIS yöntemleriyle talep tahmini çalışması yapmışlar RMSE analiziyle ANFIS daha iyi sonuç verdiği ortaya

koymuşlardır. Boltürk (2013), bir şirket için elektrik tüketim verilerini baz alarak hareketli ortalama, holt modeli, üstel düzeltme, regresyon, bulanık mantık, yapay sinir ağları, ARIMA, gri teori yöntemleri uygulayarak MSE, ortalama mutlak sapma, MAPE ve R Kare yöntemleri kullanarak karşılaştırma yapmış farklı tüketim dönemlerinde farklı yöntemlerin doğru sonucu verdiğiine ulaşmıştır. Es vd. (2014), Türkiye'deki net enerji talep tahmini yapabilmek amacıyla nüfus, yurtiçi gayrisafi hasıla, ithalat, ihracat, bina yüzölçümü vb. veriler baz alınarak YSA ve Çoklu Regresyon Analizi yapmıştır. Hata kareleri toplamı ve MAPE analizi karşılaştırmasında YSA'nın kabul edilebilir ve yüksek doğrulukta tahmin yapmış olduğu sonucuna ulaşmışlardır. Ukuş (2014), buğday ve unlu mamuller üreten bir firma için satış adetleri ve satış gelirlerini kullanım yerlerine göre gruplandırıp elde edilen verileri veri madenciliği yöntemi ile talep tahmini çalışması yapmıştır. Firmaya pazarlama stratejileri önermiştir. Kumar vd. (2014), endüstriyel valf üreten bir firmada satış adetlerinden yapay sinir ağının farklı öğrenme yöntemlerini kullanarak karşılaştırmalı analiz yapmış MSE analiziyle trainlm öğrenme yönteminin diğerlerine göre daha iyi sonuç verdiği sonucuna ulaşmışlardır. Demirci (2015), cam sektöründe faaliyet gösteren bir şirkette 36 aylık satış verilerini baz alarak hareketli ortalama, üstel düzeltme, YSA, ARIMA yöntemleri gibi farklı 6 talep tahmini yöntemiyle tahmin çalışması yapmıştır. Kullanılan yöntemlerin tahmin performansı MAE, MAPE, MSE yöntemleri kullanılarak karşılaştırılmış YSA ve ARIMA yöntemlerinin performansının diğer yöntemlerden daha iyi olduğu sonucuna ulaşmıştır. Doğan (2016), bir temizlik ürününe ait ürünün firmaya olan maliyeti, rakip ürünün fiyatı, ürünün fiyatı ve enflasyon değerini baz alarak uyarlamalı sinirsel bulanık mantık çıkarım sistemi ve yapay sinir ağı yöntemiyle talep tahmini çalışması yapıp RMSE yöntemi ile karşılaştırarak iki yöntemin beraber yapılarak tahmin yapılmasının tahmin çalışmasının doğruluğunu arttırdığı sonucuna ulaşmıştır. Akdağ (2016), su talep tahmini yapılması için ortalama hava sıcaklığı, ortalama yağış miktarı, su fiyatı, su tüketimi vb. girdileri baz alarak yapay sinir ağları, destek vektör makineleri ve Box Jenkins yöntemleri kullanarak Diyarbakır iline ait su talep tahmini çalışması yapmış yöntemlerin performanslarını MSE, RMSE, MAPE yöntemleri kullanılarak karşılaştırma yapmış YSA yönteminin diğer yöntemlere göre daha doğru sonuçlar elde ettiği sonucuna ulaşmıştır. Bhadouria ve Jayant (2017), bir dişli imalat işletmesinde dişli kutusu satış verilerini baz alarak geleneksel tahmin yöntemleri ve yapay sinir ağı yöntemiyle talep tahmini yapmış ortalama mutlak sapma (MAD), MAPE, MSE

kullanarak yapay sinir ağı yönteminin daha doğru sonuç verdiği ulaşılmıştır. Öte yandan Ergün vd. (2017), tahmin yöntemleri ve literatür taraması yaparak talep tahminine dair yöntemler ve çalışmalar ortaya koymuşlardır. Bulut ve Başoğlu (2017), Türkiye'nin kısa dönem elektrik tahmini ve geleceğe yönelik akıllı bir öngörü sistemi olan EPSİM-NN adı verilen geçmiş değerleri, GSYH, sanayi üretim endeksi ve günün hususi özelliklerini dikkate alarak yapay sinir ağı yöntemi kullanıp bir tahmin mekanizması geliştirmişlerdir. Gerçekleşen değerler MAPE ve RMSE yöntemleri ile kıyaslayarak hata payının çok düşük olduğunu ortaya koymuşlardır. Yücesan (2018), beyaz eşya sektörü için döviz kuru, tatil günleri, tüketici güven endeksi, üretici fiyat endeksi ve bölgedeki konut satışlarını baz alarak yapay sinir ağı ARIMA, ARIMAX yöntemleri kullanıp satış tahmini çalışması yapmış MSE analizi ile bu yöntemler arasından en isabetli tahmin çalışmasının yapay sinir ağı yöntemi olduğu sonucuna ulaşmıştır. Benzer şekilde Sönmez ve Zengin (2019), Tokat ilinde içecek ve yiyecek sektöründe faaliyet gösteren bir firmada enflasyon, gerçekleşen hava sıcaklığı, yiyecek türleri, haftanın günleri vb. verileri baz alıp yapay sinir ağı ve çoklu regresyon analizi yöntemleriyle talep tahmini çalışması yapmışlardır. İki yöntemin tahmin performansını karşılaştırarak yapay sinir ağı yönteminin gerçeğe daha yakın sonuç verdiği görmüşlerdir. Uzun (2019), Bursa ili ve Türkiye için orta ve uzun dönemli elektrik ihtiyacını tahmin edebilmek için geçmiş yıllara ait elektrik tüketimi, iklim, nüfus yıllık ani puan yük değeri verilerini baz alarak Çoklu Doğrusal Regresyon ve Yapay Sinir Ağı yöntemlerini kullanıp tahmin çalışması yapmıştır. MAPE ve R performans göstergeleri baz alıp TEİAŞ verileri ile karşılaştırıp performans değerlendirilmesi yapmıştır. Tekin (2019), döviz kuru tahmini yapmak için döviz kurunu etkileyen etmenleri ve değerlerini baz alarak YSA ve çoklu regresyon analizi uygulayarak yöntemlerin performansını MSE analizine göre değerlendirmiş ve yapay sinir ağları yönteminin performansının çoklu regresyon analizi yöntemlerinden daha iyi olduğu sonucuna ulaşmıştır. Aydın ve Yazıcıoğlu (2019), bir süpermarketin kasap reyonu 3 farklı ürünü için satış verilerini baz alarak YSA ve ARIMA yöntemleriyle talep tahmini çalışması yapıp MAE ve MAPE yöntemlerini kullanılarak karşılaştırmışlar ve YSA yönteminin 3 farklı ürün içinde ARIMA yöntemine göre hata oranı düşük sonuçlar ortaya koyduğunu belirlemişlerdir. Türk ve Kiani (2019), beyaz eşya sektöründe faaliyet gösteren bir firma için beyaz eşya satış adetleri, tüketici güven endeksi, reel kesim güven endeksi, gayrisafi yurtiçi hasıla, tüketim harcamaları vb. baz alarak doğrusal olmayan modellerde tahmin başarı oranı yüksek olan ileri beslemeli

geri yayılım ağı algoritması ve regresyon analizi kullanarak tahmin çalışması yapmış MSE analizine göre yapay sinir ağı yönteminin gerçeğe daha yakın olduğu sonucuna ulaşmışlardır. Lee vd. (2020), otel talep tahmini yapabilmek ve talep yöntemini karşılaştırmak amacıyla rezervasyon verileri, zaman serileri, mevsimsellik faktörlerini baz alarak zaman serisi analizi ve yapay sinir ağı yöntemiyle talep tahmini çalışması yapmışlardır. Çalışmanın sonuçlarını MAE ve geometrik ortalama göreceli hata (GMRAE) analizleriyle karşılaştırma yaparak yapay sinir ağı talep tahmini çalışmasının daha doğru sonuç verdiği sonucuna ulaşmışlardır. Alegado ve Tumibay (2020), aşı stoğunu tahmin etmek amacıyla 72 aylık aşı verilerini baz alıp ARIMA ve çok katmanlı algılayıcı sinir ağı yöntemlerini kullanmışlardır. Yapılan tahmin çalışmasının sonuçlarını RMSE ve MAE analizleriyle karşılaştırıp çok katmanlı algılayıcı sinir ağı yönteminin daha doğru sonuç verdiği sonucuna ulaşmışlardır. Aydemir (2020), bütçenin para arzı, tüketici güven endeksi, tüketici fiyat endeksi, işsizlik oranı, dolar kuru vb. etkilenme kriterlerini ve bu kriterlere ait veri değerlerini baz alınıp yapay sinir ağı yöntemi kullanarak tahmin çalışması yapmış ve YSA modellerinden MSE analizini kullanarak doğru bütçe tahminine ve kriterlerinin etkileme derecelerine göre sıralanması sonucuna ulaşmıştır. Güven (2020), perakende hazır giyim sektöründe ürün adı, renk, cinsiyet, özel gün, mağaza sayısı vb. girdileri baz alarak yapay sinir ağları, destek vektör mekanizması ve rastgele ormanlar yöntemlerini kullanarak satış tahmin çalışması yapmış sonuçları RMSE, R Kare, MSE, MAE analizleriyle karşılaştırmış ve YSA modelinin renk dahil olmadığı tahminde renk detayının dahil edildiğinde ise destek vektör makineleri yönteminin daha başarılı olduğu sonucuna ulaşmıştır. Min vd. (2021), doğal gaz talebini tahmin etmek amacıyla meteorolojik faktörleri, doğalgaz kullanım verilerini baz alıp korelasyon analizi ve yapay sinir ağı kullanıp tahmin çalışması yapmış ve korelasyon analizinin gerçeğe daha yakın sonuçlar elde ettiği sonucuna ulaşmıştır. Nebati vd. (2021), Türkiye'deki elektrik tüketimi tahmin edebilmek amacıyla elektrik tüketim verileri, nüfus, konut sayısı, kişi başına düşen milli gelir vb. kriterleri baz alarak regresyon analizi, ARIMA, zaman serisi analizleri ile tahmin yapmışlardır. Yapılan tahmin sonuçlarını MSE, MAPE, MAE yöntemlerini kullanılarak karşılaştırmışlar ve yöntemlerin birbirine yakın sonuçlar vermesinden dolayı talep tahmini çalışmasının doğru sonuçlar verdiği kanısına varmışlardır. Ecemiş (2022), paslanmaz sac satış adetlerini etkileyen dolar kuru, faiz oranı, üretici fiyat endeksi, sanayi üretim endeksi, elektrik fiyatı vb. girdileri baz alarak veri madenciliği ve zaman serisi analizi yöntemleriyle talep tahmini


yapmıştır. Tahmin sonuçları MAE, ME, MAPE, RMSE yöntemleriyle karşılaştırıp veri madenciliğinin hata oranlarının daha düşük olduğu sonucuna ulaşmıştır. Acı ve Ayyıldız Doğanşoy (2022), perakendecilik sektöründe satış verilerini, tüfe değerlerini, işsizlik oranını tatil günlerini baz alarak, makine öğrenmesi ve derin öğrenme yöntemlerini kullanarak tahmin çalışması yapmışlardır. Yapılan tahmin çalışmasının performansı korelasyon katsayısı (R), RMSE, MAE ile karşılaştırıp performanslarına göre doğru tahmin değerlerine ulaşmışlardır. Yüksel (2023), perakende sektöründe bir firmada satış verilerini kullanarak tek değişkenli ve çok değişkenli zaman serisi yöntemlerini kullanarak talep tahmini yapmıştır. Yapılan talep tahmini yöntemlerinin performanslarını MAPE, MSE ve RMSE analizleriyle karşılaştırarak en iyi performansın CastBosst modelinin sağladığı sonucuna ulaşmıştır. Ayrıca Odabaşı ve Toklu (2023), Palkadot para birimi için 2020-2023 yılları arasındaki verileri kullanarak YSA ve derin öğrenme yöntemleriyle Palkadot değeri tahmin çalışması yapmışlardır. Tahmin sonuçlarını R, MSE ve RMSE analizleriyle karşılaştırarak YSA yönteminin tahmin performansının derin öğrenmeden daha iyi olduğu sonucuna ulaşmışlardır. Benzer şekilde Erdemci ve Karaman (2023), 2020-2040 yılları arasındaki Türkiye'nin enerji talep tahminini yapmak için parçacık sürü optimizasyonu, yapay sinir ağı ve destek vektör makinesi yöntemlerini kullanmışlardır. Tahmin sonuçlarını MSE, RMSE ve ortalama mutlak hata analiziyle karşılaştırmışlar ve YSA'nın diğer yöntemlere göre daha başarılı sonuçlar elde ettiği sonucuna ulaşmışlardır.

Bu çalışmada, döküm sektöründe üretilen kritik bir parça için YSA'nın farklı aktivasyon fonksiyonları ve farklı öğrenme algoritmaları kullanılarak talep tahmini gerçekleştirilmiştir. Karşılaştırmalı analiz ile tahmin performansı yüksek olan tahmin modelinin belirlenmesi amaçlanmıştır.

2. YÖNTEM

Bu çalışmada bir firma için satış talep tahmini yapılmıştır. Uygulanan talep tahmini yöntemlerinden işletme için en uygun olan yöntem belirlenmiştir.

Mevcut elde olan verilerden yola çıkılarak gelecekte ne olacağına dair öngöründe bulunma sürecine tahmin denir. Tahmin işletmelerde, meteorolojide, sağlık sektöründe, ulaşım ve lojistik sektöründe, eğitim ve akademik araştırmalarda, enerji ve doğal kaynak kullanımlarında olmak üzere çok farklı kullanım alanına sahiptir. Kullanım alanlarında geleceğe dair daha iyi kararlar alınmasını sağlar. Tahmin çalışmalarının zaman serisi tahminleri, regresyon tahminleri, makine öğrenmesi tahminleri, derin öğrenme tahminleri gibi çeşitleri mevcuttur. Karar verme süreçlerini yönetmek, belirsizliği azaltmak amacıyla yapılan tahmin çalışması dokuz aşamadan oluşmaktadır. Tahmin aşamaları Şekil 2.1’de görüldüğü gibidir.



Şekil 2.1.Tahmin aşamaları (Ecemiş, 2022)

Şekil 2.1’de görülen tahmin aşamaları açıklanırsa;


Geçmişe ait verilerin ya da gözlemlerin toplanması veri toplama adımını oluşturur. Toplanan verilerin incelendiği aykırı verilerin ayıklandığı, verilerin

normalizasyonunun yapıldığı tahmin aşaması veri analizi ve hazırlık aşamasını oluşturur. Toplanan verilere ve yapılmak istenen tahmine uygun modelin seçildiği üçüncü tahmin aşamasıdır. Seçilen modelin verilerle eğitildiği adım dördüncü tahmin aşamasını oluşturur. Modelin tahmin performansını değerlendirmek için gerçek verilerle kıyaslanarak tahmin performansının belirlendiği aşama beşinci tahmin aşamasıdır. Modelin performansı değerlendirilip tutarlılığı görüldükten sonra geleceğe yönelik tahminler yapılır. Tahmin sonuçları değerlendirilir ve oluşan hataların nedenleri analiz edilir. Tahmin doğruluğunu iyileştirilebilecek daha doğru tahmin yapılması için yapılabilecek çalışmalar yapılır. Tahmin modelinin doğruluğu kanıtlandığında model kullanılır. Talep tahmini farklı zaman aralıklarında yapılabilir (Ukuş, 2014). Literatürde genellikle kullanılan talep tahmini zaman aralıkları beş çeşittir.

- Kısa Dönemli Tahminler: Bir haftadan altı aya kadar zaman aralığında yapılan tahminleri ifade etmekte stok ve üretim kapasitesi yönetiminde kullanılmaktadır.
- Orta Dönemli Tahminler: Bir yıldan üç yıla kadar yapılan tahminleri ifade ederken yatırım kararları, tesis planlama için kullanılmaktadır.
- Uzun Dönemli Tahminler: Üç yıldan daha uzun süreli yapılan tahminleri ifade ederken teknoloji gelişimleri, pazar eğilimlerini, işletmedeki büyük değişiklikleri yapmak için kullanılır.
- Gerçek Zamanlı Tahminler: Anlık verilere göre hızla güncellenen tahminleri ifade ederken büyük veri analizlerinde kullanılır.
- Sürekli Tahminler: Tahminlerin sürekli yapıldığı ve güncellendiğini ifade ederken değişken ve belirsiz ortamlarda kullanılmaktadır.

2.1. Talep Tahmini Yöntemleri

Tahmin yapmak için literatürde farklı yöntemler bulunmaktadır. Bu yöntemler sayısal nicel verileri kullanarak yapılan kantitatif tahmin yöntemleri ve nitel verileri kullanarak yapılan kalitatif tahmin yöntemleri olmak üzere ikiye ayrılır. Tahmin yöntemleri Şekil 2.2’de görüldüğü gibi kalitatif ve kantitatif yöntemlerin içerisinde farklı şekillerde sınıflandırılmaktadır.



Şekil 2.2.Tahmin yöntemleri

Bu çalışmada satış talep tahmini yapmak için kantitatif yöntemler altında bulunan makine öğrenimi yöntemlerinden birisi olan yapay sinir ağları ve zaman serisi yöntemleri altında bulunan ARIMA yöntemi kullanılmıştır.

2.1.1. Zaman serisi yöntemleri

Zaman serisi yöntemleri verilerin zaman içerisindeki değişimlerini belli bir zaman aralığında veya sürekli ölçen, gözlemleyen, analiz eden istatistiksel bir yöntemdir. Zaman serisi yöntemleri kullanılarak geçmiş verilerden geleceğe dair tahminler yapılabilir (Nebati vd., 2021). Zaman serisi yöntemlerine tek basamaklı hareketli ortalama, üssel hareketli ortalama, trend analizi, arıma yöntemleri örnek verilebilir.

2.1.2. Makine öğrenimi yöntemleri

Verileri kullanarak tahmin yapan bir yapay zeka alanıdır. İnsanların çalışma yöntemlerini aşarak belli görevleri bilgisayarların tek başına öğrenip yapabilir mi

sorusuna yanıt bulmak için üretilmiştir (Zilyas ve Yılmaz, 2023). Makine öğrenimi yöntemlerine lineer regresyon, rastgele ormanlar, gradient boosting ve yapay sinir ağları örnek verilebilir.

2.1.3. Derin öğrenme yöntemleri


Yapay sinir ağlarının daha kompleks desenlerini anlamak ve öğrenmek üzere kullanılmaktadır. Kökleri 1960'lara dayansa da matematiksel modeli yeni değildir. Kendi başına hangi bilgileri öğrenmesine karar verdiği için klasik yöntemlere göre başarısı daha yüksektir. Kullanıldığı alana bağlı olarak çeşitli modellerde tasarlanabilir (Kızrak ve Bolat, 2018). Derin öğrenme yöntemlerine uzun kısa vadeli hafıza ve konvolüsyonel sinir ağları örnek verilebilir.

2.2. Aykırı Veri Analizi Yöntemleri

Veriler çalışmanın performansını etkiledikleri için çalışmada uygulanan yöntem kadar önemliliğe sahiptir. Çalışma yapılmadan önce analiz edilmesi aykırı verilerin ayrıştırılması gereklidir. Literatürde aykırı veri analizi yöntemi olarak standart sapma yöntemi, box-plot grafiği, Grubbs testi, Rosner testi, Dixon testi, Weisberg t testi gibi yöntemler bulunmaktadır (Ovla ve Taşdelen, 2012). Bu çalışmada box-plot yöntemi kullanılmıştır.

2.2.1. Box-plot yöntemi

Kutu grafiği verilerin görselleştirme yapılarak aykırı verilerin belirlendiği bir yöntemdir. Beş temel hesaplama kullanılır. Kullanılan hesaplama verilerin dağılımının, basıklığının, çarpıklığının, merkezi eğiliminin nasıl olduğu hakkında çalışma yapan kişilere bilgi verir (Keskin vd., 2019).




Şekil 2.3. Kutu grafiği görselleştirmesi (Keskin vd., 2019)

Şekil 2.3’de görüldüğü gibi Box-Plot yöntemiyle veriler görselleştirilir. Veriler küçükten büyüğe doğru sıralanarak verilerin ortanca değeri kutu grafiğinin orta yerindeki çizgisini oluşturur. Oluşturulan kutunun alt çizgisi verilerin 1. Çeyreğini ifade ederken üst çizgi 3. Çeyreği ifade eder. Kutunun üst ve alt kısmından çıkan çizgiler verilerin minimum ve maksimum değerlerini gösterir. Bu çizgiler bir kurala göre belirlenir, kural ise 1. Çeyreğin 1,5 katıdır bu kadar uzatılır. Bu çizgilerin dışında kalan veriler ise aykırı değer olarak gösterilmekte ve kabul edilmektedir. Aykırı verilerin veri seti içerisinde kaldırılması analizin doğruluk derecesini arttıracaktır.

2.3. Yapay Sinir Ağları

İnsan beyninin sinir yapısının haberleşmesinden baz alınarak tasarlanan matematiksel modele yapay sinir ağları denir. Yapay sinir ağları giriş katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan meydana gelmektedir. Giriş katmanı sisteme verileri sağlarken veriler gizli katmanda işlenir ve çıktı katmanından sonuçlar elde edilir. Katmanların farklı kombinasyonlarından yapay sinir ağları meydana gelmektedir. Yapay sinir ağı yapısının detaylı görünümü Şekil 2.4’te görüldüğü gibidir.




Girdi Katmanı Gizli Katman Çıktı Katmanı

Şekil 2.4. Yapay sinir ağı yapısı

Verileri alıp işleyen ve sonucu üretenlere nöron adı verilir. Yapay sinir ağının hesaplama birimi olarak adlandırılır. Şekil 2.4'te görüldüğü gibi katmanlar arası nöron bağlantıları eğitim sürecinde ayarlanır. Veriler ile çıktı arasındaki hatayı azaltmak için nöronların ağırlıklarının güncellenmesi gereklidir. Yapay sinir ağının çalışma mantığı, verilerin girdi katmanından ağa girişi ile başlar. Verilere çıktılarına doğru ilerlerken her bağlantı üzerinde bir ağırlık ve her nöron için nöronun çıktısına eklenen sabit değeri ifade eden bias değeri hesaplanır. Nöronlardan gelen sinyallerin aktivasyon fonksiyonları sayesinde işlenerek nöronun aktivasyon seviyesi belirlenir. Girdilerden başlayarak çıktılarına doğru ileri yayılım yapılırken son katmandaki çıktılar tahmin değerlerini ifade eder. Tahmin değerleri veriler ile kıyaslanarak hata değerleri hesaplanır. Modelin performansını değerlendirmek için kullanılır. Hata geriye doğru yayılım gösterirken ağırlık ve bias değerleri güncellenir. Optimizasyon algoritmaları hatayı en aza indirecek şekilde ayarlama yapar. İleri yayılım ve geri yayılım birkaç kez tekrarlanarak en iyi tahmin yapılması sağlanır.


İnsan beyninin çalışma prensibine göre tasarlanan yapay sinir ağları enerji tüketiminde verimlilik, esneklik, paralellik yapısı, öğrenme yeteneği, hata toleransı gibi avantajlar sağlar. Çıktı kalitesinde öngörülemezlik, gündelik problemlerde problem çözücü olamama, problemi nasıl çözdüğü hakkında bilgi edinememe, problemi çözerken deneme yanılma yaparak en iyi sonucun elde edilmesi kesin sonucun bilinmemesi gibi dezavantajlara sahiptir (Demirci, 2015). Yapay sinir ağı sahip olduğu avantajlar sayesinde geniş uygulama alanına sahiptir. Uygulama alanlarına insan yüzü tanıma gibi işlemlerde kullanılan görüntü işleme, metinsel işlevlerde kullanılan doğal dil işleme, oyun ve eğlence amaçlı yazılımlar, tıbbi görüntüleme gibi sağlık sektöründe,

hata tespiti, taşıma ve lojistik işlemleri olan üretim sektöründe kullanımları örnek olarak verilebilir. Yapay sinir ağı insan beyninden esinlenerek ve insan beyninin öğrenme yapısını taklit ederek geliştirilen bir algoritmadır. Yapay sinir ağını anlamak için insan sinir hücresi incelenmelidir. Şekil 2.5’de biyolojik sinir hücresi verilmiştir.



Şekil 2.5. Biyolojik sinir hücresi (Koç vd., 2004)

Sinir ağları milyarlarca sinir hücresinden meydana gelmekte beynimizde de 10^{10} adet sinir hücresi ve bunlardan da 6×10^{13} fazla bağlantı olduğu söylenmektedir (Sarı, 2016). Biyolojik sinir hücresi Şekil 2.5’te görüldüğü gibi dendrit, sinaps, akson ve akson uçlarından meydana geldiği söylenebilir. Biyolojik sinir hücresi nöron olarak adlandırılmaktadır. Sinir hücresi diğer sinir hücrelerinden gelen etkileşimleri alan dendritler ile çevrilidir. Dendritlerde gelen etkileşimi algılayacak bir eşik değeri bulunmakta belirli eşik değeri üzerinde olan etkileşimler bir sinir hücresinden diğerine akım şeklinde devam etmektedir. Akım aksonlar aracılığıyla diğer sinir hücrelerine taşınmaktadır. Sinapslar ise uyarıcı, engelleyici ve sinaptik güç özelliklerine sahiptir. Uyarıcı sinapsler gönderici sinir hücresinden gelen sinir akımını artırırken engelleyici sinapsler gelen sinir akımını azaltır. Bu etkinin miktarını ise yine sinapslar belirler. Sinir hücresine aynı anda hem uyarıcı hem engelleyici özellikte akımlar gelmektedir. Her bir akım sayısal olarak bir ağırlığa sahip olduğu için ağırlıklar uzun dönemli olarak akson tepeciğinde toplanır. Toplanan akımlar eğer eşik değerinden yüksekse akım devamı sağlanır. Bu işlemlerin uzun süre devam etmesiyle sinir hücreleri öğrenmiş olur (Boltürk, 2013). Biyolojik sinir hücresinden esinlenerek oluşturulan yapay sinir ağının matematiksel yapısı Şekil 2.6’da görüldüğü gibidir.



Şekil 2.6. Yapay sinir ağı matematiksel yapısı (Karahan, 2011)

Yapay sinir ağı matematiksel modeli Şekil 2.6’da de görüldüğü gibi 5 ana bileşenden oluşmaktadır. Bunlar girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktıdır. X_n Değerleri girdileri, w_n değerleri ağırlıkları, Σ toplama fonksiyonunu, $f(x)$ aktivasyon fonksiyonunu bunlar sonucunda çıktı oluşmakta ve Q eşik değerini ifade etmektedir. Şekil 2.6’da görüldüğü gibi yapay sinir ağı matematiksel modelinde sinir hücresinden veya dış etmenlerden gelen veriler girdiyi oluştururken, girdilerin yapay sinir ağı üzerindeki önemini ağırlıklar ifade etmektedir. Girdiler kendi değeri ile çarpılarak toplama fonksiyonu aracılığıyla toplanır, toplanan veriler bir sınır fonksiyonu aracılığıyla bir seviye yani eşik değeri belirlenir. Eşik değeri üzerindeki veriler işleme girer, aktivasyon fonksiyonu aracılığıyla çıktı oluşur (Aydemir, 2020).

Yapay sinir ağı ve biyolojik sinir hücre eleman benzetimi Tablo 2.1’de görüldüğü gibidir.


Tablo 2.1. Yapay sinir ağı ve biyolojik sinir hücresi elemanları (Demirci, 2015)

Yapay Sinir Ağı	Biyolojik Sinir Hücresi
Sinir	Düğüm, Nöron
Bağlantı ağırlıkları	Sinaps
Toplama İşlevi	Dendrit
Aktivasyon Fonksiyonu	Hücre Gövdesi
Sinir Çıkışı	Akson

2.3.1. Yapay sinir ağı mimarisi


İki veya iki den daha fazla yapay sinir hücresinin bir araya gelmesiyle yapay sinir ağları meydana gelir. Tek sinir hücresi normal yaşamda karşılaşılan problemlerin çözümüne karşı yetersiz kalırken karmaşık yapıda olan yapay sinir ağları problemlerin çözümünde etkilidir. Yapay sinir hücrelerinin birbirinden ayrı bağlanma şekillerine “Topoloji” adı verilir. Çok sayıda topoloji şekli bulunmaktadır. Çok sayıda bağlanma şekli bulunurken ana iki bağlanma şekli bulunmaktadır. Bunlar ileri beslemeli ağlar, geri beslemeli ağlar olarak adlandırılmaktadır (Saatçioğlu & Özçakar, 2016).

İleri Beslemeli Yapay Sinir Ağı: İleri beslemeli yapay sinir ağı Şekil 2.7’de görüldüğü üzere girdi verilerinin katmanlar arasında geri dönüşü olmadan girdi katmanından çıkışa doğru hareket halinde olduğu yapay sinir ağıdır.



Şekil 2.7.İleri beslemeli yapay sinir ağı (Saatçioğlu & Özçakar, 2016)

Geri Beslemeli Yapay Sinir Ağı: Geri beslemeli yapay sinir ağı Şekil 2.8’de görüldüğü gibi girdilerin katmanlar arasında geri dönüşlerinin olduğu yapay sinir ağlarının dinamik hafızalarının olduğu ağlardır. Bu sayede çıktıların tekrardan girdi olabileceği yapay sinir ağları oluşur.




Şekil 2.8. Geri beslemeli yapay sinir ağı (Saatçioğlu & Özçakar, 2016)

2.3.2. Aktivasyon fonksiyonu


Yapay sinir ağında girdi ve ağırlık değerini alarak nöronun çıktısını belirleyen matematiksel işleve aktivasyon fonksiyonu adı verilmektedir. Literatürde 4 ana aktivasyon fonksiyonu bulunmaktadır. Bunlar doğrusal fonksiyon, hiperbolik tanjant fonksiyonu, sigmoid fonksiyon ve basamak fonksiyonudur. Fonksiyon seçimine göre verilerin normalleştirme formülleri değişmektedir (Sarı, 2016).

Doğrusal Fonksiyon: Nöronların doğrusal bir işlem yaparak yani girdilerin ağırlıklarla çarpılması sonucu çıktıyı hesapladığı fonksiyondur. Doğrusal fonksiyona ait grafik Şekil 2.9’da görüldüğü gibidir.



Şekil 2.9. Doğrusal fonksiyon grafiği (Uzun, 2019)

Hiperbolik Tanjant Fonksiyonu: -1 ile 1 arasında çıktı değerleri oluşturan hiperbolik tanjant fonksiyonu girdilerin tanjant fonksiyonundan geçirilmesi ile çıktı elde eder. Hiperbolik tanjant fonksiyonuna ait grafik Şekil 2.10’da görüldüğü gibidir.



Şekil 2.10. Hiperbolik tanjant fonksiyon grafiği (Uzun, 2019)


Hiperbolik tanjant fonksiyonu (2.1)'deki denklem gibi ifade edilir.

$$tansig(x) = \frac{e(x) - e(-x)}{e(x) + e(-x)} \quad (2.1)$$

Hiperbolik tanjant fonksiyonunda veriler normalleştirme yapmak için (2.2)'deki denklem kullanılarak normalleştirme yapılır.

$$x_{norm} = 2 \times \left(\frac{x - x_{min}}{x_{max} - x_{min}} \right) - 1 \quad (2.2)$$

Sigmoid Fonksiyon: Yapay sinir ağında en sık kullanılan fonksiyon olan sigmoid fonksiyon çıktı değeri olarak 0 ile 1 arasında değer üretir. Sürekli artan bir fonksiyon olan sigmoid fonksiyon doğrusal olan ve doğrusal olmayan davranışlar arasında denge sağlar. Sigmoid fonksiyona ait grafik Şekil 2.11'de görüldüğü gibidir.



Şekil 2.11. Sigmoid fonksiyon grafiği (Uzun, 2019)


Sigmoid fonksiyon (2.3) denklemindeki gibi ifade edilir.

$$\text{logsig}(x) = \frac{1}{1 + e^{-x}} \quad (2.3)$$

Sigmoid fonksiyon kullanıldığında veriler denklem (2.4) kullanılarak normalleştirme yapılır.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (2.4)$$

Basamak Fonksiyonu: Tek katmanlı ağlarda kullanılan eşik (basamak) fonksiyonu 0 ile 1 arasında çıktı değeri oluşturmaktadır. Basamak fonksiyonuna ait grafik Şekil 2.12’de görüldüğü gibidir.



Şekil 2.12. Basamak fonksiyon grafiği (Uzun, 2019)

2.3.3. Yapay sinir ağı öğrenme yaklaşımları

Yapay sinir ağını eğitmek, eğitirken optimize etmek amacıyla yapay sinir ağına danışmanlı öğrenme, danışmansız öğrenme ve takviyeli öğrenme olmak üzere öğrenme yaklaşımları vardır. Kullanılan veriye, yapay sinir ağı kullanım amacına göre öğrenme yaklaşımları farklılık göstermektedir.

Danışmanlı Öğrenme: Yapay sinir ağına girdi ve çıktı değerleri verilerek eğitilirken çıktıya göre hata hesaplaması yapıp hatayı en az olmasını sağlamak için kullanılan öğrenme yaklaşımıdır. Sınıflandırma ve regresyon çalışmalarında kullanılmaktadır.

Danışmansız Öğrenme: Verilen verileri kendi içlerinde sınıflandırarak veya azaltarak öğrenme yaparken verilerdeki desenleri keşfeder. Kümeleme ve anormallik tespiti gibi alanlarda kullanılır.

Takviyeli Öğrenme: Kullanım amacına uygun olarak bulunduğu çevreden veri topladığı, topladığı verileri kullanarak sorunu optimize edip çözüm ürettiği bir öğrenme yaklaşımıdır. Ajan verilen görevleri optimize ederek yerine getirmesine göre puan almaktadır. Bu öğrenme yaklaşımı oyunlarda, robot kontrollerinde kullanılmaktadır.

2.3.4. Geri yayılım öğrenme algoritmaları

Geri yayılım öğrenme algoritmaları hatayı azaltmak için hatanın çıkış katmanından geriye doğru yayılarak her katmandaki nöron katkısı hesaplanıp hesaplanan katkıya göre ağırlıkların güncellenmesini ifade eder. Geri yayılım optimizasyon algoritmasında birden fazla öğrenme algoritması bulunur.

MATLAB yazılımında farklı öğrenme algoritmaları bulunmaktadır. Bu çalışmayı diğer çalışmalardan farklı kılan birden fazla öğrenme algoritması kullanarak modeller oluşturmak ve farklı modelleri karşılaştırıp tahmin performansı en yüksek öğrenme algoritmasını tespit etmektir. Çalışmada ileri beslemeli geri yayılım algoritması altında kullanılan öğrenme algoritmaları `trainlm`, `traincgf`, `traincgb`, `traingdx`, `traincgp`, `trainscg`, `traingda` ve `traingd` olmak üzere sekiz farklı öğrenme algoritmasıdır.

Trainlm (levenberg-marquardt) algoritması: Büyük yapay sinir ağlarında daha az verimli, orta ölçekli yapay sinir ağlarında daha hızlı bir yöntem olan `trainlm` algoritması Levenberg- Marquardt optimizasyonuna göre ağırlık ve sapmayı ayarlamaktadır. Diğer algoritmalara göre bazı uygulamalarda daha iyi eğitim performansına sahip, çok verimlidir. Bazı problemlerde ise çok önemli olabilecek matrislerin tutulmasını gerektirmesi en büyük dezavantajıdır (Abdellah vd., 2021).

Traincgf (conjugate gradient fletcher reeves) algoritması: Çok sayıda ağırlığa sahip ağlar için kullanılan `traincgf` algoritması daha fazla bellek gerektirir. Kayıp fonksiyonu negatif eğim boyunca en hızlı şekilde azalırken en hızlı yakınsamaya yol açmaz. Problemden probleme farklılık gösterse de genellikle `traingda` ve `traingdx`'e göre hız olarak önemli ölçüde daha hızlıdır (Abdellah vd., 2021).

Traincgb (conjugate gradient polak-ribiere) algoritması: Ağırlıkları güncellemek için gradyan inişi ve konjugate gradient yöntemini kullanan `traincgb` algoritması mevcut eğim ile önceki eğim arasındaki dikliği kontrol ederek her yinelemede adım boyutunu ayarlayarak öğrenme gerçekleştirir (Kuok & Bessaih, 2007).

Traingdx (gradient descent with momentum) algoritması: Traingda'nın bir uzantısı olan traingdx ağırlık ve sapma değerlerini gradyan iniş momentumuna göre ve uyarlanabilir bir öğrenme oranına göre güncelleyen bir öğrenme algoritmasıdır. Her değişken momentumlu gradyan inişine göre ayarlanır. Maksimum tekrar sayısı, maksimum süre eğitimin sonlandırılmasına neden olur (Prema vd., 2016).

Traincgp (conjugate gradient powell-beale) algoritması: Traincgp öğrenme algoritması Fletcher-Ribière eşlenik geri yayılım algoritmasıdır. Bayesian yaklaşımı ile ağırlık güncellemesi yaparak aşırı uyuma karşı dirençli ağırlar elde etmeyi amaçlar (Hernández vd., 2014).

Trainscg (scaled conjugate gradient) algoritması: Geri yayılım öğrenme algoritmalarından bir tanesi olan ölçeklendirilmiş eşlenik gradyan algoritması büyük ağların eğitiminde hızlı kovaryans sağlar. Öğrenme maksimum tekrar sayısına ulaştığında, performans hedefe göre en aza indiğinde, azami süre aşıldığında durur (Hartono vd., 2018).

Traingda (gradient descent with adaptive learning rate) algoritması: Yapay sinir ağında aşırı ve az öğrenmeyi önlemek için uyarlanabilir bir öğrenmeye sahip gradyan iniş yöntemi olan traingda algoritması ağırlık büyük hata artışları olmadan öğrenme oranını artırır. Bu sayede optimale yakın öğrenme oranı elde ederek hatanın garanti edilemeyecek kadar yüksek olduğunda istikrarlı öğrenme yeniden olana kadar öğrenme oranı azalır. Azami süre, tekrar sayısı, performans eğimi minimum gradyan altına düşmesi durumunda eğitim sonlanır (Prema vd., 2016).

Traingd (gradient descent) algoritması: Ağırlık değerlerini performans fonksiyonunun negatif gradyan iniş yönünde güncelleyen traingd öğrenme algoritması hedef, zaman, minimum gradyan değerlerini baz alarak öğrenme sürecini devam ettirir. Öğrenme oranı parametresi ağırlık değerlerini belirlemek için eğimin negatifi ile çarpar. Öğrenme oranı büyüklüğü ile öğrenme adımı doğrusal orantılıdır. Öğrenme oranı çok büyük olduğunda algoritma kararsız kalırken oran küçük olduğunda yakınsama uzun zaman alır (Majid vd., 2011).

2.4. ARIMA

ARIMA yöntemi Box-Jenkins yöntemleri altında bulunan bir zaman serisi analiz yöntemidir. ARIMA'yı diğer zaman serisi analiz yöntemlerinden ayıran durağan

serilere uygulanıyor olmasıdır. Durağan olması demek verilerin birbirine benzer olması anlamına gelmektedir. Serinin durağan olup olmadığı zaman serisi, ACF, PACF grafiklerinden anlaşılrsa da sayısal olarak kanıtlanmak istendiğinde Augmented-Dickey Fuller test yapılır. Augmented-Dickey Fuller test birim kök testlerinin genişletilmiş versiyonudur (Başaran Caner ve Engindeniz, 2020).

ARIMA yöntemi üç bileşenden oluşmaktadır. Bu üç bileşen AR (AutoRegressive), I (Integrated) ve MA (Moving Average)'dır.

- AR (AutoRegressive) geçmiş değerlerden yola çıkılarak geleceği tahmin etmeyi ifade ederken önceki zaman dilimlerindeki değerlerle mevcut zaman dilimindeki değerler arasındaki ilişkiyi bulmayı amaçlar ve “p” ile ifade edilir. P değeri kaç zaman dilimi geriye gidilerek otoregressive ilişkinin analiz edileceği anlamına gelmektedir.
- I (Integrated) Zaman serisinin durağan olması için alınması gereken fark sayısını ifade ederken “d” ile gösterilir.
- MA (Moving Average) zaman serisi içerisinde rastgele dalgalanmaları zaman serisinin gürültüsünü modellerken geçmişteki verilerin gelecekteki veriler için nasıl kullanılabileceğini tanımlarken “q” ile ifade edilir. Q değeri zaman dilimi içerisinde geriye gidilerek hareketli ortalamanın analiz edileceğini göstermektedir (Yıldırım ve Altunç, 2020).

Genel ARIMA denklemi (2.5)'de ifade edildiği gibidir (Akdağ, 2016).

$$F_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \Delta^d y_t + \phi_1 \varepsilon_{t-1} + \dots + \phi_q \varepsilon_{t-q} \quad (2.5)$$

(2.5) denkleminde görülen ϕ_p gecikmeli değerlerin şimdiki değerlerle ilişkisini gösterirken, Δ fark almayı, d fark alma derecesini, ε_t hata terimini, ϕ_q gözlem değeri ile o dönemdeki ve geçmiş dönemdeki hata değeri arasındaki ilişkiyi ifade etmektedir (Akdağ, 2016).

2.5. Hata Analiz Yöntemleri

Farklı talep tahmin yöntemleri gerçekleşen değerleri alıp kullanarak geleceğe dair tahminler yapar. Bu tahminlerin gerçeği ne ölçüde yansıtıp yansıtmadığı, kullanılabilir kullanılamaz olduğunu kanıtlayan hata analizi istatistiksel yöntemleri literatürde bulunmaktadır. Hata analiz yöntemleri yapılan tahmin çalışmasının performans

değerini ortaya koyduğundan ve yöntemlerin kıyaslanması sağladığından çok önemlidir. Gerçekleşen ve tahmin edilen değerleri farklı yönlerden karşılaştıran farklı hata analiz yöntemleri vardır. Bu yöntemlerin en iyisinin hangisi olduğu kullanılan veri, yapılan tahminin amacı, uygulanan tahmin yöntemine göre farklılık göstermektedir. En iyi hata analiz yöntemi şudur diyerek kesin bir yöntem söylemek doğru değildir. Bu yüzden çalışmalarda aynı anda farklı hata analiz yöntemleri kullanılarak o çalışma için en doğru sonucun hangisi olduğuna karar verilmelidir. Literatürde tahmin çalışmalarında, yapay sinir ağı ve arıma karşılaştırmalarında sık sık kullanılan hata tahmin analizleri ortalama mutlak hata, ortalama kare hata, kök ortalama kare hata, r kare analizi ve ortalama mutlak yüzde hatadır (Demirci, 2015).

2.5.1. Ortalama mutlak hata (MAE)

Ortalama mutlak hata tahmin edilen değerlerin gerçek değerlerden mutlak değer olarak ne kadar saptığını analiz eden hata analiz yöntemidir. Ortalama mutlak hata değeri arttıkça tahmin değerinin gerçek değerden uzaklaştığı anlaşılmaktadır. İstenilen ortalama mutlak hata değerinin küçük olmasıdır. Ortalama mutlak hata denklemi (2.6) 'da ifade edildiği gibidir.

$$MAE = \frac{1}{n} * \sum_{i=1}^n |x_i - x| \quad (2.6)$$

n : gözlem sayısı

x_i : Gerçek değer

x : Tahmin değeri

2.5.2. Ortalama kare hata (MSE)

Ortalama kare hata tahmin değerlerinin gerçekleşen değerlerden farkının karelerinin toplamının deneme sayısına bölünmesiyle elde edilmektedir. Gerçek değerden ortalama karesel olarak ne kadar saptığını gösteren hata analiz yöntemidir. Ortalama kare hatanın az olması istenmekte ortalama kare hata değeri arttıkça gerçek değerden sapmanın da arttığı anlaşılmaktadır. Ortalama kare hata denklemi (2.7) denkleminde ifade edildiği gibidir.

$$MSE = \frac{1}{n} * \sum_{i=1}^n (x_i - x)^2 \quad (2.7)$$

n : gözlem sayısı

x_i : Gerçek değer

x : Tahmin değeri

2.5.3. Kök ortalama kare hata (RMSE)

Kök ortalama kare hata tahmin değerlerinin gerçek değerden kök ortalama olarak ne kadar saptığını ifade etmektedir. Kök ortalama kare hata analizinin sonucunun küçük olması istenir. Kök ortalama kare hata değerinin artması tahmin değerinin gerçek değerden sapmasının da arttığını ifade etmektedir. Kök ortalama kare hata analizine ait denklem (2.8)'de görüldüğü gibidir.

$$RMSE = \sqrt{\frac{1}{n} * \sum_{i=1}^n (x_i - x)^2} \quad (2.8)$$

n : gözlem sayısı

x_i : Gerçek değer

x : Tahmin değeri

2.5.4. R kare analizi (R^2)

R kare analizi bağımsız değişkenlerin bağımlı değişkenler üzerindeki varyansını gösteren bir hata analiz yöntemidir. Tahmin çalışmalarında r kare değerinin yüksek olması modelin doğruluğunun yüksek olduğunu ifade etmektedir. R kare analizine ait denklem (2.9)'da görüldüğü gibidir.

$$R^2 = 1 - \frac{SSR}{SST} \quad (2.9)$$

SSR : Hata Kareleri Toplamı

SST: Toplam Kareler Toplamı

$$SSR = \sum_{i=1}^n (x_i - x)^2$$

$$SST = \sum_{i=1}^n (x_i - X)^2$$

n: gözlem sayısı

x_i: Gerçek değer

x: Tahmin değeri

X: Gerçek değerlerin ortalaması

2.5.5. Ortalama mutlak yüzde hata (MAPE)

Ortalama mutlak yüzde hata tahmin değerlerinin gerçek değerlerden yüzde kaç oranında saptığını gösteren hata analiz yöntemidir. Ortalama mutlak yüzde hata değerinin küçük olması beklenmektedir. Değer büyüdükçe tahmin değerinin gerçek değerlerden sapması artmaktadır. Ortalama mutlak yüzde hata analizi için kullanılan denklem (2.10)'da görüldüğü gibidir.

$$MAPE = \frac{1}{n} * \sum_{i=1}^n \left| \frac{x_i - x}{x} \right| * 100 \quad (2.10)$$


n: gözlem sayısı

x_i: Gerçek değer

x: Tahmin değeri

3. UYGULAMA

Bu bölümde yöntem bölümünde açıklanmış olan tahmin yöntemlerinden Yapay Sinir Ağı yönteminin farklı katman, nöron, öğrenme algoritmaları ve ARIMA yöntemi kullanılarak talep tahmini çalışması yapılmıştır. Bu çalışmanın uygulaması döküm sektöründe öncü bir firmada gerçekleştirilmiştir. Talep tahmini uygulaması için özellikle üretimde dar boğaz oluşturan ve talebinde dalgalanmalar yaşanan bir parça aile grubu seçilmiştir. Yapılan çalışmanın uygulama akış planı Şekil 3.1’de görüldüğü gibidir. Öncelikle talebi etkileyen kriterler belirlenmiştir. Bu kriterler belirlenirken öncelikle literatür araştırması gerçekleştirilmiştir. Literatürden elde edilen kriterler uzman görüşünün onayına sunulmuş ve son hal verilmiştir. Yöntemin gerektirdiği aktivasyon fonksiyonu, öğrenme algoritması, katman ve nöron sayıları belirlenip talep tahmini çalışması yapılmıştır. Sonraki aşamada, parçaya ait satış adetleri kullanılarak ARIMA yöntemi uygulanmıştır. Uygulanan yöntem sonuçlarıyla gerçekleşen satış adetleri karşılaştırılıp tahmin performansı en iyi talep tahmini yöntemi ve modeli belirlenmiştir.



Şekil 3.1. Uygulamanın akış planı

3.1. Döküm Sektörü

Metallerin ergitilerek kalıba dökülmesiyle çeşitli parçaların elde edildiği endüstri dalı olan döküm sektörü farklı sektörlerde kullanılan parçaların üretilmesini sağlamaktadır. İstenilen şekle uygun bir kalıbın hazırlanması, parçanın kullanım alanına ve özelliklerine uygun metalin ergitilerek madenin hazırlanması, madenin kalıba dökülmesi, kalıbın soğuması ve parçanın kalıptan çıkarılması ile istenen parça meydana gelmektedir. Döküm sektörü geri dönüşümü mümkün olan malzemelerin yeniden kullanılmasını sağlayarak çevre açısından uygunken seri üretimde maliyetleri düşürmek ve parçaların hassasiyetini düşürmesi bakımından avantajlıdır. Türkiye’deki döküm süreçleri; demir, çelik, alüminyum, bakır, bronz ve dökme demir gibi çeşitli döküm yöntemleri kullanılarak gerçekleştirilmektedir. Dökme demir yöntemiyle çeşitli otomotiv parçaları üretilmektedir (Baş, 2022).

3.2. Çalışmada Kullanılacak Parçanın Seçilmesi

Çalışmada kullanılan parça, kum kalıba döküm yöntemi ile elde edilmektedir. Otomotiv sektörü açısından önemli bir konumda bulunmaktadır. Ayrıca işletme içerisinde üretim istasyonlarında kapasite olarak dar boğaza sebep olup müşteri tarafında ise talep olarak belirsiz talebe sahiptir. Parçanın talebinin belirsiz olması ve dar boğaz oluşturması sebebiyle uygulamada bu otomotiv parçası ele alınmıştır. Bu çalışma ile ilgili parça için en uygun talep tahmin yönteminin belirlenmesi ve müşteriye tam zamanında sevkiyat yapılması hedeflenmektedir.

3.3. Satışı Etkileyen Girdilerin Belirlenmesi

Döküm yapılarak üretilen parçalar direkt olarak son kullanıcıların kullanımına uygun değildir. Firmanın üretmiş olduğu parçalar araçların motor, şanzıman, aks, fren diski gibi aksamlarıdır. Bu yüzden otomotiv fabrikalarına satılmakta, otomotivler ile son kullanıcılara ulaşmaktadır. Otomotiv satışları ile paralel olarak satışlar değişmekte otomotiv sektöründeki dalgalanmalar ile parça satışlarında da dalgalanmalar yaşanmaktadır.

Çalışmada kullanılmış olan girdiler uzman görüşleri alınarak ve literatür taraması yapılarak aşağıdaki gibi belirlenmiştir.

- Büyük Kamyon Üretim Adeti
- Elektrik Birim Fiyatı

- Euro Kuru
- Yurtiçi Üretici Fiyat Endeksi
- Genel Tüketici Fiyat Endeksi
- Brent Petrol Varil Fiyatı
- Hurda Ortalama Fiyatı
- Türkiye'nin İthal Ettiği Pig Fiyatları
- Gayri Safi Yurtiçi Hasıla

Seçilen parça tırın aksamıdır. Tırın aksamı olduğu için tırın satışları parçanın satışını etkileyecektir. Bu yüzden çalışmaya büyük kamyon üretim adeti girdi olarak seçilmiştir. Seçilen girdinin 2017 ve 2022 yıllarına ait aylık verileri otomotiv sanayi derneğinin otomotiv sanayi üretim bültenlerinden alınmıştır (OSD, 2017-2022). Firmada elektrik en çok kullanılan girdilerden bir tanesidir. Ergitme işlemi elektrik ile ergitme ocaklarında yapılmaktadır. Elektrik fiyatları değişkenlik gösterdiğinde parça maliyetinde değişme olduğu için parçanın fiyatı da değişmektedir. Parçanın fiyatı satışı etkileyeceği için girdi kriteri olarak seçilmiştir. Kriter verileri olarak Türkiye İstatistik Kurumu'nun (TÜİK) yayınlamış olduğu 2017 ve 2022 yılları arasındaki aylık tüketim aralıklarına göre sanayi elektrik fiyatları kullanılmıştır (TÜİK, 2017-2022). 2022 yılının 2. çeyrek fiyatlarına dair TÜİK açıklaması olmadığı için yapılan zam oranları baz alınarak fiyatlarda artış yapılmış çalışmada kullanılmıştır.

Parçanın satışı Euro olarak yapılmaktadır. Euro kurunun değişkenliği satışları etkilemektedir. Türkiye Cumhuriyeti Merkez Bankasının yayınlamış olduğu 2017 ve 2022 yılları arasındaki aylık Euro kuru verileri çalışmada kullanılmıştır (TCMB, 2017-2022).

Ülkenin kendi üretimi altındaki mal ve hizmetin üretim aşamasındaki fiyat değişimlerini baz alarak oluşturulan yurtiçi üretici fiyat endeksinin çalışmaya katkısı olacağı için TÜİK'in açıklamış olduğu 2017 ve 2022 yılları arasındaki aylık yurtiçi üretici fiyat endeksi verileri çalışmada kullanılmıştır (TÜİK,2017-2022).

Bir ülkedeki tüketilen mal ve hizmetlerin genel fiyatını ölçen genel tüketici fiyat endeksinin talebi etkileyeceği uzmanlar tarafından belirlenmiştir. Belirlenen kritere ait veriler Türkiye Cumhuriyeti Merkez Bankasının 2017 ve 2022 yılları arasındaki aylık yayınlanan verileridir (TCMB, 2017-2022).

Kamyon satışları parçanın satışını etkilemektedir. Kamyonun kullanmış olduğu petrol fiyatının değişmesi kamyon satışını dolaylı olarak parça satışını etkileyeceği düşünüldüğünden enerji bilgi yönetimi tarafından yayınlanan 2017 ve 2022 yılları arasındaki aylık brent petrol varil fiyatı verileri çalışmaya girdi olarak eklenmiştir (EBY, 2017-2022).

Parçanın üretiminde hammadde olarak kullanılan hurdanın ortalama fiyatı parça fiyatına yansıtılmaktadır. Hurda fiyatları parça fiyatlarına yansıtıldığı için parçanın satışını etkileyeceği uzmanlar tarafından belirlenerek çalışmanın girdileri arasına dahil edilmiştir. Çalışmada kullanılan veriler TÜDOKSAD tarafından yayınlanan 2017 ve 2022 yıllarına ait aylık hurda ortalama fiyatı verileridir (TÜDOKSAD,2017-2022).

Döküm sektörünün en pahalı hammaddelerinden birisi olan pik fiyatları direk ürünün satış fiyatına eklenmektedir. Bu yüzden uzman görüşleri ile çalışmaya da girdi olarak eklenmiştir. Girdiye ait veriler çelik sektörü bilgisi tarafından yayınlanan Türkiye'nin ithal ettiği pik fiyatlarının 2017 ve 2022 aylarına ait aylık verileridir (SIK, 2017-2022).

Ülkenin ekonomik performansını ölçme ve karşılaştırma amacıyla kullanılan gayrisafi yurtiçi hasıla otomotiv sektörünü etkilemektedir. Otomotiv sektörünü etkilediği için döküm sektörü de etkilenmektedir. Bu yüzden çalışmaya girdi olarak seçilmiştir. Seçilen girdiye ait veriler TÜİK tarafından açıklanan 2017 ve 2022 yıllarını kapsayan aylık verilerdir (TÜİK, 2017-2022).

Çalışmada çıktı olarak ise seçilen parça aile grubunun 2017 ve 2022 yılları arasındaki satış adetleri baz alınmıştır.

3.4. Uygulamada Kullanılan Tahmin Yöntemleri

Çalışmada Yapay Sinir Ağı ve ARIMA yöntemleri kullanılarak talep tahmini yapılmıştır. Yapay Sinir Ağı yönteminde farklı nöron, katman ve öğrenme algoritmaları kullanılarak modeller oluşturulmuştur. Oluşturulan modeller arasında tahmin performansı en iyi model ortalama mutlak hata, ortalama kare hata, kök ortalama kare hata ve r kare analizi kullanılarak karşılaştırılıp en iyi yapay sinir ağı modeli belirlenmiştir. Yapay sinir ağı modeli belirlendikten sonra ARIMA yöntemiyle de yapay sinir ağı modelinin ve ARIMA yönteminin tahmin performansı karşılaştırması yapılmıştır.

3.4.1. Yapay sinir ağı uygulaması

İnsan beyninin çalışma yapısından esinlenerek oluşturulan yapay sinir ağı genellikle tahmin yapmak, karmaşık veri desenlerini tespit etmek, veri analizi yapmak için kullanılır. Literatürde yapılan talep tahmini çalışmalarında başarılı sonuç verdiği için çalışmada yapay sinir ağı yöntemi seçilmiştir.

Yapay sinir ağı algoritması seçilmesi: Çalışmada yapay sinir ağı algoritması kullanılarak döküm sektörü parça talep tahmini yapılmaktadır. Gerçek değer ve hedef değer arasındaki hatayı hesaplayarak kıyaslama yapıldığı için yapay sinir ağı eğitim sürecinde hata miktarını geriye doğru yayan geri yayılım algoritması kullanılmıştır. Çalışmada diğer çalışmalardan farklı olarak geri yayılım algoritması içerisinde bulunan farklı öğrenme algoritmaları kullanılarak modeller oluşturulmuştur.

Kullanılacak öğrenme algoritmalarının belirlenmesi: Geri yayılım algoritmasının kullanıldığı yapay sinir ağı modellerinin eğitiminde farklı öğrenme algoritmaları mevcuttur. Çalışmada MATLAB programında nntool yapay sinir ağı toolbox'ında geri yayılım algoritmaları içerisinde bulunan Tablo 3.1'deki öğrenme algoritmaları ile modeller oluşturulmuştur. Oluşturulan modellerin talep tahmini performansları karşılaştırılmıştır.


Tablo 3.1. Karşılaştırma yapmak için kullanılan öğrenme algoritmaları tablosu

Algoritma Kısaltması	Algoritma İsmi
1 Trainlm	Levenberg-Marquardt algoritması
2 Traincgf	Conjugate Gradient Fletcher Reeves (CGF) algoritması
3 Traincgb	Conjugate Gradient Polak-Ribière (CGB) algoritması
4 Traingdx	Gradient Descent with Momentum (GDX) algoritması
5 Traincgp	Conjugate Gradient Powell-Beale (CGPI) algoritması
6 Trainscg	Scaled Conjugate Gradient (SCG) algoritması
7 Traingda	Gradient Descent with Adaptive Learning Rate (GDA) algoritması
8 Traingd	Gradient Descent (GD) algoritması

Aktivasyon fonksiyonunun seçilmesi: Yapay sinir ağı yönteminin MATLAB uygulamasında kullanılan tansig, logsig ve purelin olmak üzere üç farklı aktivasyon fonksiyonu vardır. Literatürde tansig ve logsig aktivasyon fonksiyonları daha sık

kullanıldığından dolayı çalışmada tansig ve logsig aktivasyon fonksiyonları için ayrı ayrı modeller oluşturulmuştur. Modellerin tahmin performansları karşılaştırılmıştır.

Veri analizi: Çalışmada kullanılan yöntem kadar kullanılan veriler de önemlidir. Veriler arasında bulunan tutarsızlıklar çalışmayı tamamen yanlış bir sonuca yönlendirebilir. Yanlış bir sonuca ulaşılmaması amacıyla veriler ile işlem yapılmadan önce veri ön işleme yapılmalıdır. Bunun için veri ayrıştırma yöntemi olan Box-Plot analizi SPSS aracılığıyla gerçekleştirilmiştir. Box-Plot analizi verilerin ortalama değerleri baz alınarak uygulanmıştır. SPSS programında uygulanan verilerin ortalama değerine göre Box-Plot analizinin sonucu Şekil 3.2’de görüldüğü gibidir.



Şekil 3.2. SPSS Box-Plot analiz sonucu


Şekil 3.2’de görüldüğü gibi veri setinde bulunan 63, 69, 70 ve 71. sıradaki veriler veri seti içerisindeki ayırık verilerdir. Çalışma yapılmadan önce veri seti içerisinde çıkarılması gereklidir.

Verilerin Normalizasyonu: Yapay sinir ağı tasarımında verilerle işlem yapılmadan önce tüm verilerin aynı türden olması için verilere normalleştirme işlemi yapılması gereklidir. Normalleştirme işlemi seçilen aktivasyon fonksiyonuna göre farklılık göstermektedir. Çalışmada aktivasyon fonksiyonu olarak hem logsig hem tansig seçildiği için yöntem bölümünde belirtilen aktivasyon fonksiyonlarında kullanılan normalleştirme formülleri girdilere ait verilere uygulanarak normalleştirme işlemi yapılmıştır. **Deneme yapılacak katman ve nöron sayısının seçilmesi:** Çalışmada kullanılacak olan katman ve nöron sayıları deneme-yanılma yöntemiyle belirlenmiştir. Belirlenen katman ve nöron sayıları Tablo 3.2’de görüldüğü gibidir.

Tablo 3.2. Belirlenen katman ve nöron sayıları


	Katman Sayısı	Nöron Sayısı
1	1	0
2	2	8
3	2	10
4	2	20
5	2	30
6	3	8
7	3	10
8	3	20
9	3	30

Yapay sinir ağı MATLAB uygulaması: Verileri eğitim, test ve doğrulama olarak %70-%15-%15 düzeyinde MATLAB programı kendiliğinden seçmiştir. Normalleştirme yapılmış olan veriler MATLAB programına aktarılarak giriş verileri ve çıkış verileri tanımlanmıştır. MATLAB programının nntool fonksiyonu aracılığıyla yapay sinir ağı toolbox'ına geçilmiştir. Çalışmanın nasıl yapıldığına R Kare analizine göre tahmin performansı en yüksek tansig aktivasyon fonksiyonu, traincgb öğrenme algoritması, 2 katman 10 nörona sahip tahmin modelinden örnek verilirse: MATLAB programına tanımlanan değerler YSA için girdi değerleri ve hedef değerleri olarak tanımlanır. Yapay sinir ağı tasarımı nntool'da bulunan yardımcı toolbox ile Şekil 3.3'te görüldüğü gibi modele ait girdi, hedef değer, aktivasyon fonksiyonu, öğrenme algoritması seçilerek ağ tasarımı yapılır.




Şekil 3.3. Ağ tasarımı

Dokuz kriterli, bir çıkışlı, tansig aktivasyon fonksiyonlu, traincgb öğrenme algoritmalı, 2 katman ve 10 nörondan oluşan yapay sinir ağı modeli Şekil 3.4'te görüldüğü gibidir.




Şekil 3.4. 2 katman 10 nöron traincgb yapay sinir ağı modeli

Oluşturulan yapay sinir ağı modelinin eğitim ve test aşamasına geçilir. Modelin eğitimine ait bilgiler Şekil 3.5'te görüldüğü gibidir.




Şekil 3.5.Yapay sinir ağı eğitim bilgileri

Şekil 3.5 açıklandırırsa data division veri kümesinin doğrulama, eğitim ve test olarak random olarak bölündüğünü, öğrenme algoritmasının traincgb olduğunu, modelin performansının mse kullanılarak ölçüldüğünü, iterasyon sayısını veren epoch 544 değeri eğitim veri setinin yapay sinir ağına 544 kez sunulduğunu ve ardından hata değeri hesaplandığını, gradient öğrenme algoritmasında en hızlı artış yönünü ve miktarını göstermektedir. Eğitim, doğrulama ve test regresyon grafikleri Şekil 3.6'da görüldüğü gibidir.



Şekil 3.6. Eğitim, doğrulama ve test regresyon grafikleri

Yapılan eğitim sonucunda modelin eğitim veri seti üzerindeki performansı, eğitim ilerledikçe kayıp fonksiyonunu gösteren training grafiğinde görülmektedir. Eğitim iterasyonlarına karşı doğruluk oranını gösteren validation grafiğidir. Çıktı değerine karşılık gerçek değerle karşılaştırıp gösteren test grafiği Şekil 3.6’da görüldüğü gibidir. Eğitim R=0.99, Validation R=0.95, Test R=0.94 değerleri yapılan çalışmanın kabul edilebilir olduğunu göstermektedir. Ortalama karesel hata ve iterasyon sayını gösteren performans grafiği Şekil 3.7’de verilmiştir.



Şekil 3.7. Epoch MSE Grafiği


Eğitim karesel hata değeri eğitim süreci ilerledikçe model daha iyi eğitildiği için azalır. Şekil 3.7’de bu yapay sinir ağı modelinde de azaldığı görülmektedir. Test veri seti üzerindeki eğitim verileri iyi performans gösteriyorsa test karesel hata değeri de azalır. Doğrulama veri seti eğitim sırasında kullanılmayan bir veri seti olduğundan dolayı modelin performansını değerlendirmek için kullanılır. Doğrulama mse değeri en küçük olduğunda genel performansın en iyi olduğu kabul edilir. Best değeri bunu ifade etmektedir. Şekil 3.7’de bu yapay sinir ağı modeline ait iterasyonlara karşılık gelen mse grafiği değerleri bulunmaktadır.

Yapay sinir ağı eğitilip geçerli sonuç elde edildikten sonra yapay sinir ağının elde etmiş olduğu tahmin değerlerine simulate network işlemi yapılır ve modelin tahmin değerleri elde edilir. Elde edilen değerler modelin tahmin performansını değerlendirmek için kullanılacaktır. Tüm aktivasyon fonksiyonları, öğrenme algoritmaları, belirlenen katman ve nöron sayıları için yapay sinir ağı modelleri oluşturulup tahmin değerleri elde edilmiştir.

3.4.2. ARIMA yöntemi uygulaması


ARIMA yöntemi uygulaması için MATLAB programı kullanılmıştır. Çalışmaya ait satış verileri MATLAB programına tanımlanmış ve MATLAB programında bulunan görülen computational finance uygulaması içerisindeki econometrik modeller toolbox’ı aracılığıyla ARIMA yöntemi uygulanmıştır. Ekonomik modeller toolbox’ı açıldıktan sonra gibi çalışmaya ait satış verileri ARIMA yöntemine tanımlanır.

ARIMA yöntemi durağanlık testi: ARIMA istatiksel yöntemi uygulanabilmesi için serinin durağan olması gereklidir. Serinin durağan olması demek verilerin zamana bağlı olarak değişmediği istatiksel trend veya düzensizlik göstermediği anlamına gelir. Durağanlık zaman serisi, ACF, PACF grafikleri üzerinde görülebilir. Ya da Augmented Dickey-Fuller testi yapılarak da belirlenebilir (Berk ve Uçum, 2019). Şekil 3.8’de satış verilerine ait zaman serisi grafiği görünmektedir.




Şekil 3.8. Satış verileri zaman serisi grafiği

Şekil 3.9’da ACF ve Şekil 3.10’da PACF grafikleri görünmektedir.



Şekil 3.9. ACF grafiği



Şekil 3.10. PACF grafiği

Grafikler incelendiğinde ani artış ve azalışlar vardır serinin durağan olmadığı görülmektedir. Serinin durağan olmadığını netleştirmek amacıyla ADF testi yapılır.

Augmented dickey-fuller test: Şekil 3.8, Şekil 3.9 ve Şekil 3.10’da grafiklerde ani artış ve azalışlar olduğu için serinin durağan olmadığı görülmektedir. Fakat serinin durağan olmadığını netleştirmek amacıyla ADF testi yapılmıştır. Yapılan teste ait test parametreleri Tablo 3.3’te test sonuçları ise Tablo 3.4’te verilmiştir.

Tablo 3.3. Test parametreleri

	Lags	Model	Test Statistic	Significance Level
1	0	AR	t1	0.05


Tablo 3.4. ADF test sonuçları

	Null Rejected	P-Value	Test Statistic	Critical Value
1	False	0.062366	-1.8435	-1.9449

Tablo 3.3’te gösterilen test parametreleri: lags geçmiş değerlerin serinin tahmininde ve otokorelasyonun hesaplanmasında kullanılan gecikme sayısını, model hangi modelin kullanılacağını, 0.05 ise hipotez testinin anlamlılık düzeyini gösterir. Tablo 3.4’te gösterilen ADF test istatistiği kritik değer ile karşılaştırılır. Test istatistiği kritik değerden büyük olduğu için serinin durağan olmadığı kesinleşmiş olur ve ARIMA


yapılabilmesi için fark alınması gerektiği ortaya çıkar (Tortum vd., 2014). Böylelikle AR-I-MA yönteminin I'sı 1 olarak değerlendirilmeye başlanır.

I=1 Fark alma işlemi: MATLAB programı aracılığıyla I=1 için fark alma işlemi yapılarak yeni zaman serisi grafiği Şekil 3.11'deki gibi elde edilir.




Şekil 3.11. 1 Fark alma işlemi yapılmış zaman serisi grafiği

Fark alınmış serinin ACF grafiği Şekil 3.12'deki, PACF grafiği Şekil 3.13'teki gibidir.



Şekil 3.12. Fark alınmış ACF grafiği



Şekil 3.13. Fark alınmış PACF grafiği

Fark alma işleminden sonra oluşturulan zaman serisi, ACF ve PACF grafiklerinde ani değişimlerin ortadan kalktığı, serinin durağanlaştığı görülmektedir. Fakat durağanlığı netleştirmek amacıyla yeniden ADF testi yapılır.

I=1 Fark alınmış serinin ADF testi: I=1 Fark alınmış seri için ADF testi yapılır. Yapılan teste ait parametreler Tablo 3.5'te, fark alınmış serinin ADF test sonuçları Tablo 3.6'da verilmiştir.

Tablo 3.5. Fark alınmış serinin test parametreleri

	Lags	Model	Test Statistic	Significance Level
1	0	AR	t1	0.05

Tablo 3.6. Fark alınmış seri ADF test sonucu

	Null Rejected	P-Value	Test Statistic	Critical Value
1	True	0.001	-11.1365	-1.9449

Tablo 3.6'da görüldüğü gibi test istatistiği kritik değerden küçük olduğu için seri durağan hale gelmiş AR-I-MA modelinin I=1 olarak kesinleşmiştir. I=1 olarak belirlendikten sonra AR-I-MA yöntemi için farklı modeller önerilmiştir.

Çalışmaya ait önerilen modeller Tablo 3.7'de verilmiştir.

Tablo 3.7. ARIMA yöntemi için önerilen modeller

Model No	Önerilen Modeller (AR-I-MA)
1	(1,1,0)
2	(1,1,1)
3	(1,1,3)
4	(3,1,1)
5	(3,1,3)

Önerilen modeller arasında hangisinin tercih edilmesi gerektiğini, modelin kalitesini, hatayı minimize ederek modelin karmaşıklığını kontrol eden Akaike Bilgi Kriteri değeri gösterir. En küçük AIC değerine sahip model diğer modellere göre daha iyi uyum sağladığını ve daha az karmaşık olduğunu gösterir (Çakan, 2020). Bu çalışmaya göre tercih edilmesi gereken ARIMA modeli iki numaralı model numarasına ait ARIMA (1,1,1)'dir.

3.5. Yapay Sinir Ağı ve ARIMA Uygulama Sonuçları

Yapılan literatür taramasında yapay sinir ağı modellerinin tahmin performansları MAE, MSE, RMSE, R Kare ve MAPE hata analizleri yöntemleri ile karşılaştırıldığı görülmüştür. Bu yüzden bu çalışmada da bu hata analiz yöntemleri kullanılmıştır. Çalışmanın en iyi üç yapay sinir ağı modelleri MAE hata analiz yöntemine göre Tablo 3.8'de, MSE hata analiz yöntemine göre Tablo 3.9'da, RMSE hata analiz yöntemine göre Tablo 3.10'da, R kare hata analiz yöntemine göre Tablo 3.11'de ve MAPE hata analiz yöntemine göre Tablo 3.12'de gösterilmiştir.

Tablo 3.8. Ortalama mutlak hata (MAE) analizine göre en iyi üç yapay sinir ağı

Algoritma	Katman Sayısı	Nöron Sayısı	Fonksiyon	Ortalama Mutlak Hata (MAE)
TRAINCGB	3	30	LOGSIG	0.033
TRAINCGB	2	30	LOGSIG	0.037
TRAINCGB	3	20	LOGSIG	0.041

Tablo 3.8’de görüldüğü gibi MAE hata analiz yöntemine göre traincgb öğrenme algoritması, 3 katman 30 nöron ve logsig aktivasyon fonksiyonlu yapay sinir ağı modelinin tahmin performansı en yüksektir.

Tablo 3.9. Ortalama kare hata (MSE) analizine göre en iyi üç yapay sinir ağı

Algoritma	Katman Sayısı	Nöron Sayısı	Fonksiyon	Ortalama Kare Hata (MSE)
TRAINLM	2	10	LOGSIG	0.004
TRAINCGB	3	20	LOGSIG	0.006
TRAINCGB	2	30	LOGSIG	0.006

Tablo 3.9’da görüldüğü gibi MSE hata analiz yöntemine göre trainlm öğrenme algoritması, 2 katman 10 nöron ve logsig aktivasyon fonksiyonlu yapay sinir ağı modelinin tahmin performansı en yüksektir.

Tablo 3.10. Kök ortalama kare hata (RMSE) analizine göre en iyi üç yapay sinir ağı

Algoritma	Katman Sayısı	Nöron Sayısı	Fonksiyon	Kök Ortalama Kare Hata (RMSE)
TRAINLM	2	10	LOGSIG	0.065
TRAINCGB	3	20	LOGSIG	0.076
TRAINCGB	2	30	LOGSIG	0.078

Tablo 3.10’da görüldüğü gibi RMSE hata analiz yöntemine göre trainlm öğrenme algoritması, 2 katman 10 nöron ve logsig aktivasyon fonksiyonlu yapay sinir ağı modelinin tahmin performansı en yüksektir.

Tablo 3.11. R Kare analizine göre en iyi üç yapay sinir ağı

Algoritma	Katman Sayısı	Nöron Sayısı	Fonksiyon	R Kare
TRAINCGB	2	10	TANSIG	0.915
TRAINLM	2	10	LOGSIG	0.907
TRAINCGB	3	20	LOGSIG	0.869

Tablo 3.11’de görüldüğü gibi R Kare hata analiz yöntemine göre traincgb öğrenme algoritması, 2 katman 10 nöron ve tansig aktivasyon fonksiyonlu yapay sinir ağı modelinin tahmin performansı en yüksektir.

Tablo 3.12. Mutlak ortalama yüzde hata (MAPE) analizine göre en iyi üç yapay sinir ağı

Algoritma	Katman Sayısı	Nöron Sayısı	Fonksiyon	Mutlak Ortalama Yüzde Hata (MAPE)
TRAINCGB	3	30	LOGSIG	0.06
TRAINCGB	2	10	LOGSIG	0.12
TRAINCGB	3	10	LOGSIG	0.14

Tablo 3.12’de görüldüğü gibi MAPE hata analiz yöntemine göre traincgb öğrenme algoritması, 3 katman 30 nöron ve logsig aktivasyon fonksiyonlu yapay sinir ağı modelinin tahmin performansı en yüksektir. Hata analiz yöntemleri sonuçları farklı açılardan yorumladığı için farklı sonuçlar vermesi normaldir. Bu çalışmada yapay sinir ağı modellerinden en iyisini belirlemek için R Kare hata analiz yöntemi sonuçları baz alınmıştır. En iyi yapay sinir ağı modelinin 0.915 R Kare değerine sahip tansig aktivasyon fonksiyonlu, traincgb öğrenme algoritmalı, 2 katman 10 nörona sahip yapay sinir ağı modeli olduğu görülmüştür. ARIMA modelleri arasından AIC değerine göre tahmin performansı en yüksek çıkan ARIMA (1,1,1) modelinin tahmin performansı en yüksek yapay sinir ağı modeliyle karşılaştırılması gereklidir. Çalışmada ARIMA sonucuyla yapay sinir ağı sonucu da R Kare hata analiz yöntemi baz alınarak karşılaştırma yapılmıştır. İki uygulama sonucuna ait R Kare değerleri Tablo 3.13’de görüldüğü gibidir.

Tablo 3.13. Yapay sinir ağı ve arıma yöntemlerinin R Kare sonuçları


Algoritma	Katman Sayısı	Nöron Sayısı	Fonksiyon	R Kare
TRAINCGB	2	10	TANSIG	0.915
ARIMA (1,1,1) Modeli				0.206

Tablo 3.13’de görüldüğü gibi R Kare hata analiz yöntemine göre yapay sinir ağı modelinin 0.915 R kare değerine göre ARIMA modelinden tahmin performansının daha yüksek olduğu görülmüştür.

Yapay sinir ağı modelinde R kare değerinin çok yüksek olması halinde modelde aşırı öğrenme durumu (overfitting) incelenmelidir. Modelde aşırı öğrenme durumunun olup olmadığı grafiksel analiz yapılarak kontrol edilebilir. Grafiksel analize göre eğitim performansı artarken doğrulama performansı bir noktadan sonra düşmeye başlarsa

aşırı öğrenme durumu var olarak yorumlanmaktadır. Çalışmada belirlenen en iyi YSA modeline ait performans grafiği için Şekil 3.7 incelendiğinde böyle bir durum olmadığı belirlendiğinden yapay sinir ağı modelinde aşırı öğrenme durumu olmadığı sonucuna ulaşılmıştır.

Yapay sinir ağı traincgb öğrenme algoritması 2 katman 10 nöron tansig aktivasyon fonksiyonlu modelin tahmin edilen satış değerleri ile gerçekleşen satış değerleri grafiği Şekil 3.14'te görüldüğü gibidir.



Şekil 3.14. Gerçekleşen ve Tahmin Edilen Satış Değerleri

Şekil 3.14'te de görüldüğü gibi yapay sinir ağı modeli gerçeğe çok yakın tahmin değerleri elde etmiştir.



4. SONUÇ VE ÖNERİLER

Geçmişteki veriler baz alınarak geleceğe dair öngörülerde bulunmak amacıyla tahmin yapılır. Tahmin farklı kullanım alanlarına sahiptir. Şirketler geleceğe dair tahmin yaparak müşteri taleplerini zamanında karşılamayı önceden aksiyon almayı hedeflerler. Bu çalışmada bir döküm fabrikasında üretimde dar boğaza sebep olan ve müşteri tarafında talebinde çok dalgalanmalar yaşanan bir otomotiv parçası aile grubunda satış âdetinin tahmin edilerek ilerleyen zamanlarda müşteri talebini karşılamak, müşteri kaybını önlemek ve üretimde aksiyon alabilmek amacıyla talep tahmini yapılmıştır. Çalışmada öncelikle farklı model denemeleri ile Yapay Sinir ağı yöntemi sonrasında ARIMA yöntemi uygulanarak sonuçlar karşılaştırılmıştır. Talep tahmini çalışmasında satış etkileyen kriterler literatür taraması yapılarak ve uzman görüşü alınarak büyük kamyon üretim adetleri, elektrik birim fiyatı, Euro kuru, yurtiçi üretici fiyat endeksi, genel tüketici fiyat endeksi, brent petrol varil fiyatı, hurda ortalama fiyatı, Türkiye'nin ithal ettiği pik fiyatları gayrisafi yurtiçi hasıla belirlenmiştir. Belirlenen kriterler yapay sinir ağının trainlm, traincgf, traincgb, traingdx, traincgp, trainscg, traingda ve traingd öğrenme algoritmaları, logsig ve tansig aktivasyon fonksiyonları kullanılarak 1 katman 0 nöron, 2 katman 8 nöron, 2 katman 10 nöron, 2 katman 20 nöron 2 katman 30 nöron, 3 katman 8 nöron, 3 katman 10 nöron, 3 katman 20 nöron, 3 katman 30 nöron olmak üzere 144 adet yapay sinir ağı modeli oluşturulmuştur. Yapılan yapay sinir ağı uygulamasında farklı hata analiz yöntemleri ile modeller karşılaştırılmış ve R kare hata analiz yöntemine göre en iyi yapay sinir ağı modelinin traincgb öğrenme fonksiyonlu 2 katman 10 nörona sahip tansig aktivasyon fonksiyonlu model olduğu sonucuna ulaşılmıştır. Ayrıca ARIMA yöntemiyle sadece satış adetleri baz alınarak tahmin çalışması yapılmıştır. ARIMA modelleri arasında AIC değeri baz alınıp en iyi ARIMA modelinin ARIMA(1,1,1) olduğu sonucuna ulaşılmıştır. ARIMA (1,1,1) ile Yapay Sinir ağı R kare hata analiz yöntemiyle karşılaştırılmış ve yapay sinir ağı yönteminin ARIMA'dan tahmin performansının daha yüksek olduğu sonucuna ulaşılmıştır. Çalışma farklı katman nöron sayıları, farklı öğrenme algoritmaları ve farklı satış değerleri ile geliştirilip hem işletme için hem de literatür için faydalı olacak sonuçlar elde edilebilir.



KAYNAKLAR

- Abdellah, A. R., Mahmood, O. A., Kirichek, R., Paramonov, A., & Koucheryavy, A. (2021). Machine Learning Algorithm for Delay Prediction in IoT and Tactile Internet. *Future Internet*, 13(12), Article 12. <https://doi.org/10.3390/fi13120304>
- Acı, M., & Ayyıldız Doğanşoy, G. (2022). Makine öğrenmesi ve derin öğrenme yöntemleri kullanılarak e-perakende sektörüne yönelik talep tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(3), Article 3. <https://doi.org/10.17341/gazimmfd.944081>
- Akdağ, R. (2016). Yapay Sinir Ağları, Destek Vektör Makineleri ve Box-Jenkins Yöntemleriyle Kentsel İçmesuyu Talebi Tahmini ve Karşılaştırmalı Analizi. *Business & Economics Research Journal*, 7(1).
- Akgül, B. (2010). *Türkiye'deki Otomotiv Sektörü ve Örnek Bir Talep Tahmin Çalışması* [Yüksek Lisans Tezi]. Yıldız Teknik Üniversitesi Sosyal Bilimler Enstitüsü.
- Akyurt, İ. Z. (2015). Talep Tahmininin Yapay Sinir Ağlarıyla Modellenmesi: Yerli Otomobil Örneği. *Ekonometri ve İstatistik Dergisi*, 23, 147-157.
- Alegado, R. T., & Tumibay, G. M. (2020). Statistical and Machine Learning Methods for Vaccine Demand Forecasting: A Comparative Analysis. *Journal of Computer and Communications*, 08(10), Article 10. <https://doi.org/10.4236/jcc.2020.810005>
- Arsy, F. A. (2021). Demand Forecasting of Toyota Avanza Cars in Indonesia: Grey Systems Approach |. *International Journal of Grey Systems*, 1(1), 38-47. <https://doi.org/10.52812/ijgs.24>
- Aydemir, M. (2020). *Yapay Sinir Ağları ile Bütçe Gelirlerinin Tahmini* [Yüksek Lisans Tezi]. İnönü Üniversitesi Sosyal Bilimler Enstitüsü.
- Aydın, M. R., & Yazıcıoğlu, O. (2019). *Yapay Sinir Ağları ile Talep Tahmini: Perakende Sektöründe Bir Uygulama*. 18(35), 43-55.
- Baş, B. (2022). *GG25 Esaslı Dökme Demir Motor Bloklarının Üretimi ve Özelliklerinin İncelenmesi*. Sakarya Üniversitesi Fen Bilimleri Enstitüsü.
- Başaran Caner, C., & Engindeniz, S. (2020). Türkiye'de Pamuk Üretiminin ARIMA Modeli İle Tahmini. *Tarım Ekonomisi Dergisi*, 26(1), 63-70. <https://doi.org/10.24181/tarekoder.681079>
- Berk, A., & Uçum, İ. (2019). Türkiye'nin Nohut Üretiminin ARIMA Modeli ile Tahmini. *Journal of the Institute of Science and Technology*, 9(4), 2284-2293. <https://doi.org/10.21597/jist.544619>
- Bhadouria, S., & Jayant, A. (2017). Development of ANN Models for Demand Forecasting. *American Journal of Engineering Research*, 6(12), 142-147.

- Boltürk, E. (2013). *Elektrik Talebi Tahmininde Kullanılan Yöntemlerin Karşılaştırılması* [Doktora Tezi]. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Bulut, M., & Başoğlu, B. (2017). Kısa Dönem Elektrik Talep Tahminleri İçin Yapay Sinir Ağları ve Uzman Sistemler Tabanlı Hibrid Tahmin Sistemi Geliştirilmesi. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 32(2). <https://doi.org/10.17341/gazimmfd.322184>
- Çakan, V. A. (2020). Türkiye Yaş İncir Üretimi ve Kuru İncir İhracatı için Öngörü: ARIMA Modeli Yaklaşımı. *Tekirdağ Ziraat Fakültesi Dergisi*, 17(3), 357-368.
- Demirci, N. (2015). *Cam Sektöründe Talep Tahmin Yöntemlerinin Uygulanması ve Değerlendirilmesi* [Yüksek Lisans Tezi]. İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Doğan, O. (2016). Uyarlamalı Sinirsel Bulanık Çıkarım Sisteminin (ANFIS) Talep Tahmini için Kullanımı ve Bir Uygulama. *Dokuz Eylül Üniversitesi İktisadi İdari Bilimler Fakültesi Dergisi*, 31(1), 257-288.
- EBY (2017-2022, Aralık). Brent Petrol Varil Fiyatı, Aralık 2022. Erişim Adresi: <https://www.eia.gov/dnav/pet/hist/LeafHandler.ashx?n=PET&s=RB RTE&f=M> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- Ecemiş, O. (2022). *Veri Madenciliği Yöntemleriyle Paslanmaz Çelik Sektöründe Satış Tahmini* [Doktora Tezi]. Akdeniz Üniversitesi Sosyal Bilimler Enstitüsü.
- Eken, M. H., & Çiçek, M. (2009). Türkiye’de Otomotiv Sektöründeki Ürünlerin Kredilerle Finansmanının Satışlara Etkisi. *Maliye ve Finans Yazıları*, 1(84), 61-77.
- Erciş, M. S. (2010). Pazara Yönelik Hizmet Etkinliği ve Erzurum İlindeki Otomotiv Bayilerinin Hizmet Etkinliklerine Yönelik Bir Araştırma. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 24(1), 161-174.
- Erdemci, H., & Karaman, Ö. A. (2023). *Makine Öğrenmesi Algoritmaları Kullanılarak 2040 Yılına Kadar Türkiye’nin Enerji Talep Tahmini* [Yüksek Lisans Tezi, Batman Üniversitesi Lisansüstü Eğitim Enstitüsü]. <http://earsiv.batman.edu.tr/xmlui/handle/20.500.12402/4436>
- Ergün, S., Şahin, S., & Abant İzzet Baysal Üniversitesi. (2017). İşletme Talep Tahmini Üzerine Literatür Araştırması. *Ulakbilge Dergisi*, 5(10), 469-487. <https://doi.org/10.7816/ulakbilge-05-10-11>
- Es, H., Kalender, F. Y., & Hamzaçebi, C. (2014). Yapay Sinir Ağları ile Türkiye Net Enerji Talep Tahmini. *Gazi Üniversitesi Mühendislik-Mimarlık Fakültesi Dergisi*, 29(3), 495-504. <https://doi.org/10.17341/gummfd.41725>
- Eşidir, K. A., Gür, Y. E., Yoğunlu, A., & Çubuk, M. (2022). Yapay Sinir Ağları (YSA) ve ARIMA Modelleri ile Türkiye’de Aylık Sıfır km Otomobil Satış Adetlerinin Tahmin Edilmesi. *Pamukkale Üniversitesi İşletme Araştırmaları Dergisi*, 9(2), 260-277.
- Güven, İ. (2020). *Perakende Hazır Giyim Endüstrisinde Yapay Zeka Yöntemleri ile Talep Tahmini* [Yüksek Lisans Tezi]. Karabük Üniversitesi.

- Hartono, Marifa Ahmad, A., & Sadikin, M. (2018). Comparison Methods of Short Term Electrical Load Forecasting. *MATEC Web of Conferences*, 218, 1-8. <https://doi.org/10.1051/mateconf/201821801002>
- Hernández, L., Baladrón, C., Aguiar, J. M., Calavia, L., Carro, B., Sánchez-Esguevillas, A., Pérez, F., Fernández, Á., & Lloret, J. (2014). Artificial Neural Network for Short-Term Load Forecasting in Distribution Systems. *Energies*, 7(3), Article 3. <https://doi.org/10.3390/en7031576>
- Hülsmann, M., Borscheid, D., Friedrich, C. M., & Reith, D. (2012). *General Sales Forecast Models for Automobile Markets and their Analysis*. 5(2), 65-86.
- Işık, N., Yılmaz, S. S., & Kılınç, E. C. (2017). İthal Otomobil Satışlarının Döviz Kuru Esnekliği: Türkiye Üzerine Bir Uygulama. *Karamanoğlu Mehmetbey Üniversitesi Sosyal Ve Ekonomik Araştırmalar Dergisi*, 19(33), 84-92.
- Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N., & Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.
- Karahan, M. (2011). *İstatiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması* [Doktora Tezi]. Selçuk Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı.
- Karakaş, E. (2019). Türkiye'nin Otomotiv İhracat Gelirinin ARIMA Modeli ile Tahmin Edilmesi. *Yaşar Üniversitesi E-Dergisi*, 14(55), 318-328.
- Keskin, S., Aydın, F., & Yurdugül, H. (2019). Eğitsel Veri Madenciliği ve Öğrenme Analitikleri Bağlamında E-Öğrenme Verilerinde Aykırı Gözlemlerin Belirlenmesi. *Eğitim Teknolojisi Kuram ve Uygulama*, 9(1), 292-309.
- Kızrak, M. A., & Bolat, B. (2018). Derin Öğrenme ile Kalabalık Analizi Üzerine Detaylı Bir Araştırma. *Bilişim Teknolojileri Dergisi*, 11(3), 263-286. <https://doi.org/10.17671/gazibtd.419205>
- Koç, M. L., Balas, C. E., & Arslan, A. (2004). Taş Dolgu Dalgakıranların Yapay Sinir Ağları ile Ön Tasarımı. *İMO Teknik Dergi*, 225, 3351-3375.
- Kumar, P., Herbert, D. M., & Rao, D. S. (2014). Demand forecasting Using Artificial Neural Network Based on Different Learning Methods: Comparative Analysis. *International Journal for Research in Applied Science and Engineering Technology*, 2(4), 364-374.
- Kuok, K. K., & Bessaih, N. (2007). Artificial Neural Network (ANNS) For Daily Rainfall Runoff Modelling. *The Institution of Engineers*, 68(3), 31-42.
- Kuvvetli, Y., Dağsuyu, C., & Oturakçı, M. (2015). Türkiye'deki Araç Satışları için Ekonomik ve Çevresel Faktörleri Göz Önüne Alan Yapay Sinir Ağı Tabanlı Bir Tahmin Yaklaşımı. *Endüstri Mühendisliği Dergisi*, 26(3), 23-31.
- Lee, M., Mu, X., & Zhang, Y. (2020). A Machine Learning Approach to Improving Forecasting Accuracy of Hotel Demand: A Comparative Analysis of Neural Networks and Traditional Models. *Issues In Information Systems*, 21(1), 12-21. https://doi.org/10.48009/1_iis_2020_12-21
- Majid, H., Ang, J., & A Samah, A. (2011). Modeling of Two-Dimensional Warranty Policy Using Artificial Neural Network (ANN) Approach. *Journal of Computing*, 3, 48-57.

- Matsumoto, M., & Ikeda, A. (2015). Examination of Demand Forecasting by Time Series Analysis for Auto Parts Remanufacturing. *Journal of Remanufacturing*, 5(1), 1. <https://doi.org/10.1186/s13243-015-0010-y>
- Milenkovic, M., Bojovic, N., & Nuhodzic, R. (2012). A Comparative Analysis of Neuro Fuzzy and ARIMA Models for Urban Rail Passenger Demand Forecasting.
- Min, J., Dong, Y., Wu, F., Li, N., & Wang, H. (2021). Comparative Analysis of Two Methods of Natural Gas Demand Forecasting. *IOP Conference Series: Earth and Environmental Science*, 632(3), 032033. <https://doi.org/10.1088/1755-1315/632/3/032033>
- Nebati, E. E., Taş, M., & Ertaş, G. (2021). Türkiye’de Elektrik Tüketiminde Talep Tahmini: Zaman Serisi Ve Regresyon Analizi İle Karşılaştırma. *Avrupa Bilim ve Teknoloji Dergisi*, 31, 348-357.
- Odabaşı, M. B., & Toklu, M. C. (2023). Yapay Sinir Ağları ve Derin Öğrenme Algoritmalarının Kripto Para Fiyat Tahmininde Karşılaştırmalı Analizi. *Journal of Intelligent Systems: Theory and Applications*, 6(2), 96-107.
- OSD (2017-2018, Aralık). Büyük Kamyon Üretim Adeti, Aralık 2018 [Üretim Bülteni]. Erişim Adresi https://www.osd.org.tr/savedfiles/PDF/2022/02/02/%C3%9Cretim%20B%C3%BClteni%20_2018.pdf adresinden 2 Nisan 2023 tarihinde alınmıştır.
- OSD (2019-2020, Aralık). Büyük Kamyon Üretim Adeti, Aralık 2020 [Üretim Bülteni]. Erişim Adresi https://www.osd.org.tr/savedfiles/PDF/2022/02/02/%C3%9Cretim%20B%C3%BClteni%20_2020.pdf adresinden 2 Nisan 2023 tarihinde alınmıştır.
- OSD (2021-2022, Aralık). Büyük Kamyon Üretim Adeti, Aralık 2022 [Üretim Bülteni]. Erişim Adresi https://www.osd.org.tr/saved-files/PDF/2023/01/16/Otomotiv_Sanayii_Uretim_Bulteni_2022.12.pdf adresinden 2 Nisan 2023 tarihinde alınmıştır.
- Ovla, H. D., & Taşdelen, B. (2012). Aykırı Değer Yönetimi. 5, 3, 1-8.
- Özçift, B. (2018). *Otomotiv Yedek Parça Taleplerinin Tahmini için Bulanık Kümeleme Model Önerisi* [Doktora Tezi]. Kocaeli Üniversitesi Fen Bilimleri Enstitüsü.
- Öztekin, S. Ç. (2016). *Türkiye Otomobil Sektörünün Talep Analizi* [Yüksek Lisans Tezi]. Ordu Üniversitesi Sosyal Bilimleri Enstitüsü.
- Prema, K. V., Manish Agarwal, N., Murali Krishna, & Agarwal, V. (2016). Stock Market Prediction using Neuro-Genetic Model. *Indian Journal of Science and Technology*, 8(35), 1-9. <https://doi.org/10.17485/ijst/2015/v8i35/71306>
- Rožanec, J. M., Kažič, B., Škrjanc, M., Fortuna, B., & Mladenčić, D. (2021). Automotive OEM Demand Forecasting: A Comparative Study of Forecasting Algorithms and Strategies. *Applied Sciences*, 11(15), Article 15. <https://doi.org/10.3390/app11156787>
- Saatçioğlu, D., & Özçakar, N. (2016). Yapay Sinir Ağları Yöntemi ile Aralıklı Talep Tahmini. *Beykoz Akademi Dergisi*, 4(1), 1-32. <https://doi.org/10.14514/BYK.m.21478082.2016.4/1.1-32>

- Sarı, M. (2016). *Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması* [Yüksek Lisans Tezi]. Sakarya Üniversitesi Fen Bilimleri Enstitüsü.
- SIK (2017-2022, Aralık). Türkiye'nin İthal Ettiği Pik Fiyatları, Aralık 2022. Erişim Adresi: <https://www.steelonthenet.com/files/pig-iron.html> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- Sönmez, O., & Zengin, K. (2019). Yiyecek ve İçecek İşletmelerinde Talep Tahmini: Yapay Sinir Ağları ve Regresyon Yöntemleriyle Bir Karşılaştırma. *Avrupa Bilim ve Teknoloji Dergisi*, 302-308. <https://doi.org/10.31590/ejosat.638104>
- Şentürk, A. (2016). *Döküm Sektöründe İş Sağlığı ve Güvenliğinin Değerlendirilmesi*.
- Taş, L. (2020). Türkiye'de Döküm Sektöründe Çalışan Aile İşletmelerinde Modern Pazarlama. *İstanbul Ticaret Üniversitesi Girişimcilik Dergisi*, 8, 95-113.
- TCMB (2017-2022, Aralık). Euro Kuru, Aralık 2022 Erişim Adresi: https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket/#collapse_2 adresinden 2 Nisan 2023 tarihinde alınmıştır.
- TCMB (2017-2022, Aralık). Genel Tüketici Fiyat Endeksi, Aralık 2022. Erişim Adresi: <https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- Tekin, B. F. (2019). *Döviz Kuru Tahmininde Yapay Sinir Ağları Ve Çoklu Doğrusal Regresyon Analizi Performans Karşılaştırması* [Yüksek Lisans Tezi, Sivas Cumhuriyet Üniversitesi-Sosyal Bilimler Enstitüsü]. <https://acikerisim.cumhuriyet.edu.tr/xmlui/handle/20.500.12418/12417>
- Tortum, A., Gözcü, O., & Çodur, M. Y. (2014). Türkiye'de Hava Ulaşım Talebinin Arama Modelleri ile Tahmin Edilmesi. *Iğdır Üniversitesi Fen Bilimleri Enst. Der.*, 4(2), 39-54.
- TÜDOKSAD (2017-2022, Aralık). Hurda Ortalama Fiyatı, Aralık 2022. Erişim Adresi: <https://tudoksad.org.tr/dosyalar> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- TÜİK (2017-2022, Aralık). Gayrisafi Yurtiçi Hasıla, Aralık 2022 [Basın Bülteni]. Erişim Adresi: <https://data.tuik.gov.tr/Bulten/Index?p=Donemsel-Gayrisafi-Yurt-Ici-Hasila-IV.-Ceyrek:-Ekim---Aralik,-2022-49664#:~:text=%C3%9Cretim%20y%C3%B6ntemiyle%20Gayrisafi%20Yurt%20%C4%B0%C3%A7i,milyar%20669%20milyon%20olarak%20ger%C3%A7ekle%C5%9Fti> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- TÜİK (2017-2022, Aralık). Yurtiçi Üretici Fiyat Endeksi, Aralık 2022 [Basın Bülteni]. Erişim Adresi: <https://data.tuik.gov.tr/Bulten/Index?p=Yurt-Ici-Uretici-Fiyat-Endeksi-Subat-2023-> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- TÜİK (2019, Eylül). Tüketim Aralıklarına Göre Sanayi Elektrik Fiyatları, Eylül 2019 [Basın Bülteni]. Erişim Adresi: <https://data.tuik.gov.tr/Bulten/Index?p=Elektrik-ve-Dogal-Gaz-Fiyatlari-I.-Donem:-Ocak---Haziran,-2019-30609> adresinden 2 Nisan 2023 tarihinde alınmıştır.

- TÜİK (2019, Mart). Tüketim Aralıklarına Göre Sanayi Elektrik Fiyatları, Mart 2019 [Basın Bülteni]. Erişim Adresi: <https://data.tuik.gov.tr/Bulten/Index?p=Elektrik-ve-Dogal-Gaz-Fiyatlari-II.-Donem:-Temmuz---Aralik,-2018-30608> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- TÜİK (2020, Eylül). Tüketim Aralıklarına Göre Sanayi Elektrik Fiyatları, Eylül 2020 [Basın Bülteni]. Erişim Adresi: <https://data.tuik.gov.tr/Bulten/Index?p=Elektrik-ve-Dogal-Gaz-Fiyatlari-I.Donem:-Ocak-Haziran,-2020-33647> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- TÜİK (2020, Mart). Tüketim Aralıklarına Göre Sanayi Elektrik Fiyatları, Mart 2020 [Basın Bülteni]. Erişim Adresi: <https://data.tuik.gov.tr/Bulten/Index?p=Elektrik-ve-Dogal-Gaz-Fiyatlari-II.-Donem:-Temmuz---Aralik,-2019-33646> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- TÜİK (2021, Eylül). Tüketim Aralıklarına Göre Sanayi Elektrik Fiyatları, Eylül 2021 [Basın Bülteni]. Erişim Adresi: <https://data.tuik.gov.tr/Bulten/Index?p=Elektrik-ve-Dogal-Gaz-Fiyatlari-I.Donem:-Ocak-Haziran,-2021-37459> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- TÜİK (2021, Mart). Tüketim Aralıklarına Göre Sanayi Elektrik Fiyatları, Mart 2021 [Basın Bülteni]. Erişim Adresi: <https://data.tuik.gov.tr/Bulten/Index?p=Elektrik-ve-Dogal-Gaz-Fiyatlari-II.Donem:Temmuz-Aralik,-2020-37458> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- TÜİK (2022, Eylül). Tüketim Aralıklarına Göre Sanayi Elektrik Fiyatları, Eylül 2022 [Basın Bülteni]. Erişim Adresi: <https://data.tuik.gov.tr/Bulten/Index?p=Elektrik-ve-Dogal-Gaz-Fiyatlari-I.-Donem:-Ocak-Haziran-2022-45567> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- TÜİK (2022, Mart). Tüketim Aralıklarına Göre Sanayi Elektrik Fiyatları, Mart 2022 [Basın Bülteni]. Erişim Adresi: <https://data.tuik.gov.tr/Bulten/Index?p=Elektrik-ve-Dogal-Gaz-Fiyatlari-II.-Donem:-Temmuz-Aralik-2021-45566> adresinden 2 Nisan 2023 tarihinde alınmıştır.
- Türk, E., & Kiani, F. (2019). Yapay Sinir Ağları ile Talep Tahmini Yapma: Beyaz Eşya Üretim Planlaması için YSA Uygulaması. 1(1), 30-37.
- Ukuş, S. G. (2014). *Veri Madenciliğinin Satış Tahminleri Açısından Önemi ve Bir Araştırma* [Yüksek Lisans Tezi]. Galatasaray Üniversitesi Sosyal Bilimler Enstitüsü İşletme Anabilim Dalı.
- Uzun, E. (2019). *Farklı Yöntemler Kullanılarak Bursa ve Türkiye için Elektrik Enerjisi Talep Tahmini* [Yüksek Lisans Tezi]. Bursa Teknik Üniversitesi Fen Bilimleri Enstitüsü.

- Vahabi, A., Seyyedi, S., & Alborzi, M. (2016). A Sales Forecasting Model in Automotive Industry using Adaptive Neuro-Fuzzy Inference System(Anfis) and Genetic Algorithm(GA). *International Journal of Advanced Computer Science and Applications*, 7(11), 24-30. <https://doi.org/10.14569/IJACSA.2016.071104>
- Wirotcheewan, P., Kengpol, A., Ishii, K., & Shimada, Y. (2011). Modelling and Forecasting for Automotive Parts Demand of Foreign Markets on Thailand. *Applied Science and Engineering Progress*, 4(1), Article 1.
- Yanık, E. (2019). *İş Makineleri Sektöründe Yapay Sinir Ağları ile Talep Tahmini Uygulaması* [Master's Thesis]. Kırıkkale Üniversitesi.
- Yayar, R., & Yılmaz, E. (2017). İkinci El Otomobil Talep Fiyatının Regresyon Analizi: TR83 Bölgesi Örneği. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 13(1), 39-52.
- Yazıcıoğlu, N. (2010). *Yapay Zeka ile Talep Tahmini* [Yüksek Lisans Tezi]. Uludağ Üniversitesi Fen Bilimleri Enstitüsü.
- Yıldırım, A., & Altunç, Ö. F. (2020). Muş İli Süt Üretiminin ARIMA Modeli ile Tahmini. *Anemon Muş Alparslan Üniversitesi Sosyal Bilimler Dergisi*, 8(UMS'20), 137-146. <http://dx.doi.org/10.18506/anemon.832180>
- Yurtsever, M. (2022). LSTM Yöntemi ile Ekonomik Göstergeler Kullanılarak Otomobil Satış Tahmini. *Nevşehir Hacı Bektaş Veli Üniversitesi SBE Dergisi*, 12(3), 1481-1492.
- Yücesan, M. (2018). YSA, ARIMA ve ARIMAX Yöntemleriyle Satış Tahmini: Beyaz Eşya Sektöründe bir Uygulama. *İşletme Araştırmaları Dergisi*, 10(1), 689-706. <https://doi.org/10.20491/isarder.2018.414>
- Yüksel, B. (2023). Zaman Serilerinde Talep Tahmini (Demand Prediction In Time Series). *YBS Ansiklopedi*, 11(2), 1-18.
- Zilyas, D., & Yılmaz, A. (2023). Makine Öğrenmesi Yöntemleri İle Eğitim Başarısının Tahmini Modeli. *Dicle Üniversitesi Mühendislik Dergisi*, 14(3), 437-447. <https://doi.org/10.24012/dumf.1322273>



ÖZGEÇMİŞ

Ad-Soyad : Selinay KAYALI

ÖĞRENİM DURUMU:

- Lisans** : 2019, Sakarya Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği
- Yükseklisans** : 2024, Sakarya Üniversitesi, Endüstri Mühendisliği Anabilim Dalı, Endüstri Mühendisliği

MESLEKİ DENEYİM:

- 2022-Halen Döktaş Dökümcülük Planlama Mühendisi
- 2019-2022 Karbonsan Basınçlı Kaplar Planlama Mühendisi olarak çalıştı.

TEZDEN TÜRETİLEN ESERLER:

Kayalı S., Cengiz Toklu M., (2023, 9-11, Aralık) Realization of Casting Part Demand Forecast and Its Application in a Casting Factory, 15. Uluslararası İstanbul Fen, Mühendislik ve Uygulamalı Bilimlerde Bilimsel Araştırmalar Kongresi, Sakarya, Turkey

DİĞER ESERLER: