

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**OTOMOTİV YANSANAYİ FİRMASINDA YAPAY SİNİR AĞLARI İLE TALEP
TAHMİNİ**

YÜKSEK LİSANS TEZİ

Nihal KURU

İşletme Mühendisliği Anabilim Dalı

İşletme Mühendisliği Programı

HAZİRAN 2017

İSTANBUL TEKNİK ÜNİVERSİTESİ ★ FEN BİLİMLERİ ENSTİTÜSÜ

**OTOMOTİV YANSANAYİ FİRMASINDA YAPAY SİNİR AĞLARI İLE TALEP
TAHMİNİ**

YÜKSEK LİSANS TEZİ

**Nihal KURU
(507111023)**

İşletme Mühendisliği Anabilim Dalı

İşletme Mühendisliği Programı

Tez Danışmanı: Prof. Dr. Ferhan ÇEBİ

HAZİRAN 2017

İTÜ, Fen Bilimleri Enstitüsü'nün 507111023 numaralı Yüksek Lisans Öğrencisi Nihal KURU, ilgili yönetmeliklerin belirlediği gerekli tüm şartları yerine getirdikten sonra hazırladığı “**OTOMOTİV YANSANAYİ FİRMASINDA YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ**” başlıklı tezini aşağıda imzaları olan jüri önünde başarı ile sunmuştur.

Tez Danışmanı : **Prof. Dr. Ferhan ÇEBİ**
İstanbul Teknik Üniversitesi

Jüri Üyeleri : **Prof. Dr. Seniye Ümit OKTAY FIRAT**
Marmara Üniversitesi

.....
Doç. Dr. Hür Bersam BOLAT
İstanbul Teknik Üniversitesi

Teslim Tarihi : 05.05.2017
Savunma Tarihi : 09.06.2017





Aileme,



ÖNSÖZ

Bu çalışmada bir otomotiv yan sanayi firmasında talep tahmin probleminin çözümü için yapay sinir ağı yöntemi ile talep tahmin uygulaması geliştirilmiştir. Tam zamanlı üretim yapan otomotiv ana sanayi firmalarının ihtiyaçlarının zamanında karşılanması zorunluluğundan ötürü yan sanayilerin talepleri zamanında karşılaması büyük önem taşımaktadır. Taleplerin doğru zamanda, doğru miktarda karşılanabilmesi için doğru planlama kritik önem taşımaktadır. Bu planın yapılabilmesi için de doğru talep tahmin sistemi şarttır.

Çalışmam boyunca değerli fikirlerini paylaşarak çalışmama yön veren ve her türlü desteği vermekten kaçınmayan değerli hocam Prof. Dr. Ferhan Çebi'ye ve Araştırma Görevlisi Aycan Kaya'ya teşekkürü borç bilirim.

Bugünlere gelmemde en büyük pay sahibi olan annem, babam ve kardeşime göstermiş oldukları her türlü destekten ötürü teşekkür ederim.

Mayıs 2017

Nihal Kuru
(Endüstri Mühendisi)



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	vii
İÇİNDEKİLER	ix
KISALTMALAR	xi
SEMBOLLER	xiii
ÇİZELGE LİSTESİ.....	xv
ŞEKİL LİSTESİ.....	xvii
ÖZET.....	xix
SUMMARY	xxi
1. GİRİŞ.....	1
1.1 Tezin Amacı	1
1.2 Tez Planı.....	2
2. TEDARİK ZİNCİRİ YÖNETİMİ	3
2.1 Otomotiv Sektörü	5
2.2 Türkiye’de Otomotiv Sektörü	6
2.3 Otomotiv Sektöründe Tedarik Zinciri Yönetimi	6
2.4 Talep Tahminin Önemi	7
2.5 Talep Tahminin Aşamaları	7
3. TAHMİN YÖNTEMLERİ	9
3.1 Kalitatif Yöntemler	9
3.2 Kantitatif Yöntemler	10
3.2.1 Zaman serileri	10
3.2.1.1 Basit yöntemler	10
3.2.1.2 Üstel düzeltme.....	11
3.2.1.3 Box-Jenkins yöntemi.....	11
3.2.1.4 Trend analizi.....	12
3.2.2 Karma (Nedensel) yöntemler	12
3.2.2.1 Regresyon analizi	12
3.2.3 Yapay zeka sezgisel modeller	13
3.3 Tahmin Yöntemlerinin Sonuçlarının Değerlendirilmesi.....	14
3.3.1 Ortalama hata kareleri (MSE)	14
3.3.2 Ortalama mutlak hata (MAE)	14
3.3.3 Ortalama mutlak yüzde hata (MAPE).....	15
4. LİTERATÜR ARAŞTIRMASI	17
4.1 YSA ile Tahmin Çalışmaları	17
4.2 Otomotiv Sektöründe Talep Tahmin Çalışmaları	20
5. METOD.....	25
5.1 Yapay Sinir Ağları	25
5.1.1 Yapay sinir ağları tanımı.....	25
5.1.2 Yapay Sinir Ağlarının genel özellikleri	26
5.1.3 Yapay Sinir Ağlarının dezavantajları.....	27

5.1.4 Yapay Sinir Ağlarının uygulama alanları.....	28
5.1.5 Yapay Sinir Ağlarının tarihsel gelişimi.....	29
5.1.6 Yapay Sinir Ağları ile Diğer Yöntemlerin Karşılaştırılması.....	30
5.1.7 Yapay Sinir Ağlarının bileşenleri.....	32
5.1.7.1 Yapay sinir hücresi.....	32
5.1.7.2 Girdiler	33
5.1.7.3 Ağırlıklar	33
5.1.7.4 Toplama fonksiyonu.....	33
5.1.7.5 Aktivasyon fonksiyonu	34
5.1.7.6 Çıktılar.....	34
5.1.8 Yapay Sinir Ağlarının yapısı ve sınıflandırılması.....	35
5.1.8.1 Katman yapısına göre sınıflandırma	35
5.1.8.2 Bağlantı yapısına göre sınıflandırma.....	35
5.1.9 Yapay sinir ağının eğitimi ve öğrenme stratejileri	36
5.1.9.1 Danışmanlı öğrenme	37
5.1.9.2 Danışmansız öğrenme	38
5.1.9.3 Destekli (takviyeli) öğrenme	38
5.1.10 Öğrenme kuralları	39
5.1.11 Yapay sinir ağı çalışma yöntemi	39
6. UYGULAMA.....	41
6.1 Talep Tahmini Yapılacak Ürün Grubunun Seçimi.....	41
6.2 Talebi Etkileyen Faktörler	42
6.3 Tüm Girdi Değişkenleri ile Yapay Sinir Ağı Uygulaması	46
6.3.1 Öğrenme katsayısı belirlenmesi	46
6.3.2 Momentum katsayısının belirlenmesi	47
6.3.3 İterasyon sayısının belirlenmesi	48
6.3.4 Nöron sayısının belirlenmesi.....	49
6.3.5 Katman sayısının belirlenmesi	50
6.3.6 Yapay sinir ağının test edilmesi	51
6.4 Çoklu Regresyon Yöntemi ile Tahmin Uygulaması	53
6.5 Regresyonda Kullanılan Girdi Değişkenleri ile YSA	56
6.5.1 Öğrenme katsayısının belirlenmesi	56
6.5.2 Momentum katsayısının belirlenmesi	57
6.5.3 İterasyon sayısının belirlenmesi	58
6.5.4 Nöron sayısının belirlenmesi.....	59
6.5.5 Katman sayısının belirlenmesi	60
6.5.6 Yapay Sinir Ağının testi.....	61
7. SONUÇ VE ÖNERİLER.....	63
KAYNAKLAR.....	65
EKLER.....	71
ÖZGEÇMİŞ.....	73

KISALTMALAR

APS	: Advanced Planning and Scheduling, İleri Planlama ve Çizelgeleme
EDI	: Electronic Data Interchange, Elektronik Veri Transferi
GSYH	: Gayri Safi Yurt İçi Hasıla
MSE	: Mean Square Error, Ortalama Hata Kareleri
MAE	: Mean Absolute Error, Ortalama Mutlak Hata
MAPE	: Mean Percentage Absolute Error, Ortalama Mutlak Yüzde Hata
RKGE	: Reel Kesim Güven Endeksi
TGE	: Tüketici Güven Endeksi
YSA	: Yapay Sinir Ağları
MAD	: Mean Absolute Deviation, Ortalama Mutlak Sapma



SEMBOLLER

F_t	: Gelecek zaman tahmini
t	: Zaman
$A_{t-1},...,A_{t-n}$	: Geçmişte gerçekleşen değerler
n	: Dönem sayısı
w_i	: Ağırlık değeri
Y_t	: Bağımlı değişken
X_t, Z_t	: Bağımsız değişken
a, b, c	: Regresyon katsayıları



ÇİZELGE LİSTESİ

Sayfa

Çizelge 2.1 : Toplam motorlu taşıt üretimi.....	5
Çizelge 5.1 : Geleneksel yöntemler ve YSA karşılaştırma.....	31
Çizelge 5.2 : Uzman Sistemler ve Yapay Sinir Ağlarının karşılaştırılması.	32
Çizelge 5.3 : Toplama fonksiyonları.	33
Çizelge 5.4 : Aktivasyon fonksiyonları.	34
Çizelge 6.1 : Ürün grubunun tahmin-fiili karşılaştırması.....	42
Çizelge 6.2 : Öğrenme katsayısı belirlenmesi girdiler.....	46
Çizelge 6.3 : Öğrenme katsayısı belirlenmesi sonuçlar.....	47
Çizelge 6.4 : Momentum katsayısı belirlenmesi girdiler.....	47
Çizelge 6.5 : Momentum katsayısı belirlenmesi sonuçlar.....	48
Çizelge 6.6 : İterasyon sayısının belirlenmesi girdiler.....	48
Çizelge 6.7 : İterasyon sayısının belirlenmesi sonuçlar.....	49
Çizelge 6.8 : Nöron sayısının belirlenmesi girdiler.....	49
Çizelge 6.9 : Nöron sayısının belirlenmesi sonuçlar.....	50
Çizelge 6.10 : Katman sayısının belirlenmesi girdiler.....	50
Çizelge 6.11 : Katman sayısının belirlenmesi çıktılar.....	51
Çizelge 6.12 : Test sonuçları.....	52
Çizelge 6.13 : Aylık indeks değerleri.....	53
Çizelge 6.14 : Ağustos düzenlemesinden sonra test sonuçları.....	53
Çizelge 6.15 : Regresyon tahminleri ve fiili değerler karşılaştırma.....	55
Çizelge 6.16 : Ağustos düzenlemesinden sonra regresyon sonuçları.....	56
Çizelge 6.17 : Öğrenme katsayısının belirlenmesi girdiler.....	56
Çizelge 6.18 : Öğrenme katsayısının belirlenmesi çıktılar.....	57
Çizelge 6.19 : Momentum katsayısının belirlenmesi girdiler.....	57
Çizelge 6.20 : Momentum katsayısının belirlenmesi çıktılar.....	57
Çizelge 6.21 : Momentum katsayısının belirlenmesi çıktılar (Devam).....	58
Çizelge 6.22 : Çevrim sayısının belirlenmesi girdiler.....	58
Çizelge 6.23 : İterasyon sayısının belirlenmesi çıktılar.....	58
Çizelge 6.24 : İterasyon sayısının belirlenmesi çıktılar (Devam).....	59
Çizelge 6.25 : Nöron sayısı belirlenmesi girdiler.....	59
Çizelge 6.26 : Nöron sayısı belirlenmesi çıktılar.....	60
Çizelge 6.27 : Katman sayısının belirlenmesi girdiler.....	60
Çizelge 6.28 : Katman sayısının belirlenmesi çıktılar.....	61
Çizelge 6.29 : Regresyon girdileriyle YSA test sonuçları.....	61
Çizelge 6.30 : Ağustos düzenlenmesinden sonra 2. Adım YSA sonuçları.....	61



ŞEKİL LİSTESİ

Sayfa

Şekil 2.1 : Klasik Tedarik Zinciri Yönetimi.	3
Şekil 2.2 : Klasik Tedarik Zinciri Yönetimi.	4
Şekil 3.1 : Talep tahmin yöntemleri.	9
Şekil 4.1 : Literatür özeti.	23
Şekil 4.2 : Literatür özeti devam.	24
Şekil 5.1 : Yapay Sinir Ağlarının yapısı.	26
Şekil 5.2 : Geleneksel yöntemlerle ve YSA ile tahmin süreci karşılaştırma.	31
Şekil 5.3 : İleri beslemeli yapay sinir ağları yapısı.	36
Şekil 5.4 : Geri beslemeli yapay sinir ağları yapısı.	36
Şekil 5.5 : Danışmanlı öğrenme yapısı.	37
Şekil 5.6 : Danışmansız öğrenme yapısı.	38
Şekil 5.7 : Destekli öğrenme yapısı.	38
Şekil 6.1 : Talebin değişimi Mayıs 2014-Aralık 2016.	42
Şekil 6.2 : Otomobil satışı Mayıs 2014-Aralık 2016.	42
Şekil 6.3 : Otomobil üretimi Mayıs 2014- Aralık 2016.	43
Şekil 6.4 : GSYH 2014-2016 arası değişimi.	43
Şekil 6.5 : Faiz oranlarının değişimi.	43
Şekil 6.6 : Euro kurunun değişimi.	44
Şekil 6.7 : Dolar kurunun değişimi.	44
Şekil 6.8 : Otomobil satınalma ihtimalinin değişimi.	44
Şekil 6.9 : Benzin fiyatı değişimi.	45
Şekil 6.10 : Tüketici Güven Endeksi değişimi.	45
Şekil 6.11 : Reel Kesim Güven Endeksi değişimi.	45
Şekil 6.12 : Ağın yaratılması.	51
Şekil 6.13 : Ağın parametrelerinin girilmesi.	52
Şekil 6.14 : Regresyon sonuçları.	54
Şekil 6.15 : Regresyon katsayıları.	54



OTOMOTİV YANSANAYİ FİRMASINDA YAPAY SİNİR AĞLARI İLE TALEP TAHMİNİ

ÖZET

Otomotiv sektörü tüm dünyada ekonominin önde gelen iktisadi faaliyet kollarından biridir. Her geçen gün üretim hacimleri artmaktadır. Teknolojiler ve üretim hacimleri geliştikçe de tedarik zincirine verilen önem artmaktadır. Tüm Dünyada daha önceki dönemlerde birincil önem verilen üretimin geliştirilmesi iken daha sonraki yıllarda bu önem pazarlama satış faaliyetlerine kaydırılmıştır. Günümüzde ise şirketlerin verimliliklerini, karlılıklarını arttırmak için önem verdikleri alan tedarik zinciri yönetimi olmuştur. Tedarik zinciri; üretim için gerekli olan hammadde, malzeme ihtiyaçlarının temininden müşteriye ürünün teslimine kadarki tüm süreçleri kapsamaktadır. Tüm bu süreçlerin verimli ve etkin bir şekilde yönetilmesi için ilk basamak talep öngörülerinin oluşturulmasıdır. Talep öngörülerini oluşturulduktan sonra talebin uzun, orta ya da kısa vadeli oluşuna bağlı olarak; stratejik planlar, yatırım planları, kapasite planları, üretim planları, malzeme-işgücü-hammadde ihtiyaç planları yapılmaktadır.

Talep tahminlerinin vadesine göre ürün grubu bazında, ürün çeşidi bazında ya da ürün bazında tahminler yapılabilir. Talebin kapsadığı zaman aralığı azaldıkça ya da ürün çeşitliliği arttıkça duyarlılık artmaktadır. Tahminlerin her zaman bir hata payının olduğu unutulmamalıdır. Tahmin yöntemleri kalitatif ve kantitatif olarak iki ana gruba ayrılmaktadır. Kalitatif yöntemler sayısal olmayan, yoruma dayalı tahminler iken kantitatif tahminler sayısal veriler içeren çeşitli matematiksel işlemler sonucu elde edilen tahminlerdir. Tahmin yöntemlerinde teknolojinin gelişmesi ile birlikte yapay zeka uygulamaları da etkin bir şekilde kullanılmaya başlanmıştır. Çok çeşitli faktörleri dikkate alarak verimli sonuçlar verebilen yapay zeka uygulamalarından Yapay Sinir Ağları bu çalışmada kullanılmıştır.

Öncelikli olarak talebi tahmin edilecek olan ürün, daha önceki satış çalışanlarının öngörülerine dayanan tahminlere göre sapması yüksek olan ve satışı toplam satışın %80'ini oluşturan grup içinden seçilmiştir. Ürünün tahmin sapmaları MAPE değerlerine göre incelenmiştir.

Yapay Sinir Ağlarında daha önceki literatür çalışmaları baz alınarak otomotiv satışlarını etkileyen geçmiş dönem otomobil satışları, Türkiyede otomobil üretimi, GSYH (Gayri Safi Yurtiçi Hasıla), Euro ve Dolar kuru, araç kredisi faiz oranlarının değişimi, Tüketici Güven Endeksi, Reel Kesim Güven Endeksi, Otomobil satışları gibi değerler girdi değişkeni olarak alınmıştır. Çıktı değişkeni olarak geçmiş dönem satışları alınmıştır. Tüm değişkenlerle YSA çalışmasından sonra, aynı datalarla regresyon çalışılmıştır. Regresyonda eşdoğrusallık değerlerine bakılarak modele katılan girdi değişkenleri TGE, Faiz oranı, Otomobil üretimi ve Euro kurları alınarak tekrar YSA çalışılmıştır. Regresyon ve ilk YSA sonucundaki MAPE değerleri ve ikinci YSA sonucundaki MAPE değerleri incelendiğinde tahmin performansının arttığı gözlenmiştir.



DEMAND FORECASTING WITH ARTIFICIAL NEURAL NETWORKS IN AN AUTOMOTIVE SUPPLIER COMPANY

SUMMARY

The automotive sector is one of the leading economic sectors of the economy all over the world. Production volumes are increasing day by day. As technologies and production volumes evolve, importance attached to supply chain management is increasing. While production, across the whole world has been of primary importance in earlier periods, later, importance has been diverted to marketing and sales activities. In today's world, supply chain management has become the focus for boosting productivity and profitability. In today's world, supply chain management has become an area where companies value their productivity and profitability. Supply Chain Management's significance lies in the involvement of customers as a partner in the delivery of products and services which offers several advantages. Firstly, this integration provides the supplier information flow to the customer, removing ambiguities and allowing the supplier to better analyze the manufacturer's needs. It also enables the supplier to reduce the quantity of supply, shorten the supply period and thus reduce its costs. The customer also becomes able to respond faster. The supply chain covers all the processes from the procurement of raw material and material requirements needed for production up to the delivery of the customer's product.

The motor vehicle is composed of about 5000 parts, which are different in material structure, production type, technology. It is not possible to produce all of these parts within the parent industry. Having different options for each part, product diversity, investment needs have paved the way for the birth of automotive supplier industry to meet the needs of the industry. The parent and the supplier industries are mutually dependent on each other with regard to commercial, technical and production capacity areas.

The first step is to create demand forecasts for effective and efficient management of all Supply Chain processes. Demand forecasting is the most important business activity because it guides all other activities. Which market will be followed, how much inventory will be kept, what products will be produced, how many workers will be hired; all these decisions are derived from demand estimates. Forecasting and planning are two closely related actions. Planning is the process of choosing actions to be taken in the light of predictions. Poor forecasting leads to poor planning and poor planning leads to unwanted, unprepared situations like loss of sales and overstock.

In order to make demand forecasting, internal and external factors affecting the product demand are identified first. Then, the estimation method is selected and primary estimates are made. The consistency of these estimates is monitored and the estimation method is developed. Forecasting methods are divided into two groups, qualitative and quantitative. A number of factors must be considered in the selection of the method such as the existing time to prepare the estimation, the long or short term

of the decisions to be made, access to data, the quality of the data, the characteristics of the individuals who will apply the method, limits of variance.

After the demand forecasts have been established, depending on the long, medium or short-term nature of the demand; Strategic plans, investment plans, capacity plans, production plans, material-labor-raw material requirements plans are made.

Demand forecasts can be made on the basis of: product group, product type or product; depending on the timespan of the demand. Sensitivity increases as the covered timespan of the demand decreases or as the product variety increases. It should be taken into consideration that estimates always have margins of error. Forecasting methods are divided into two main groups as qualitative and quantitative. Qualitative methods are estimations based on non-numerical interpretations, while quantitative estimates are obtained from various mathematical operations involving numerical data.

Qualitative methods are used when the situation is not clear, when there is very little data (new product, new technology) or when intuition / experience is required. They are divided into four groups. These are managerial view, the salesperson's estimation, the Delphi method and consumer research. The managerial view is a method that takes the views of a small group of high-level managers. It is the most used method according to the other methods, except the field of product forecasting. Salesperson's estimation: Their opinion about the future of the market can be influential on demand forecasting. The Delphi method is applied to experts via a panel by addressing a number of questions about the future of the market or existing situations. Consumer research is the way companies run their research through telephone, personal interviews or questionnaires.

Quantitative methods include in mixed (experimental) methods and time series. Mixed methods use the relationship between the data from the source and the data being targeted for estimation. In the time series method, it is predicted that the past values will continue similarly. Time series are simple methods, exponential correction, weighted average, moving average, moving weighted average, Box-Jenkins, trend analysis methods. Mixed methods are regression and artificial intelligence applications. Artificial intelligence applications are Genetic algorithms, Artificial Neural Networks.

The accuracy of the estimates must be checked before the correct demand forecasting method can be selected. The prediction that gives the smallest error is the most successful one. None of the estimation methods give 100% correct results. The forecast error is the difference between the estimated value and the actual value. There are different methods of measuring prediction errors. These are mean error squares (MSE), mean absolute error (MAE), and mean absolute percent error (MAPE). Along with the development of technology in estimation methods, artificial intelligence applications have started to be used effectively. Artificial Neural Networks have been used in this study from artificial intelligence applications that can yield fruitful results taking into account a variety of factors.

Primarily; the product group for which the demand is estimated, is selected from the main group whose deviation is the highest between previous estimates based on the predictions of salespeople and whose sales constitute 80% of the total sales. The estimated deviations of the product group are examined according to the MAPE values.

Based on previous estimation studies with artificial neural network, it is seen that past automobile sales that affect past car sales, automobile production in Turkey, GDP (Gross Domestic Product), Euro and Dollar exchange rate, change in interest rates of vehicle loans, Consumer Confidence Index, Real Sector Confidence Index, gasoline prices sales were taken as input variables. In this study, as an input, the survey results of the probability of purchasing an automobile in the next 12 months of TUIK (Turkish Statistical Institute) were taken as an input. Past product sales have been received as output variable. 32-month data set was used.

Multi-layer feed forward backpropagation algorithm, which is frequently used in estimation studies, is used. Momentum Proposed Back Propagation Algorithm (traingdm) is used as training function and learngdm function is used as learning function. Log-Sigmoid (logsig) and Hyperbolic tangent sigmoid (tansig) have been tested as an activation function. With the tansig estimates were continued because of its MAPE values were lower. Matlab R2011B is used as the software. Experiments were performed to select optimum values for learning coefficient, momentum coefficient, number of iterations, number of neurons, number of layers respectively. Since there is 32 months of data available, it is used for 25 months of data training.

Firstly, the momentum coefficient for learning coefficient selection is fixed at 0.6. The appropriate learning coefficients were selected as 0.2 and 0.4. In the next step, we experimented with 0.2 and 0.4 learning coefficients and all momentum coefficients between 0.1-0.9. The appropriate combination of learning and momentum coefficients are provided in the 0.2-0.6 respectively. The appropriate number of iterations are tested with the learning coefficient is 0.2, the momentum coefficient is 0.6. The optimal number of iterations is 2250. In order to determine the number of neurons, experiments were carried out with 1-20 neuron counts. The optimum number of neurons were selected as 7. Later attempts were made to determine the number of layers. The appropriate number of layers was selected as 5. After the training of the artificial network, 7 months data for the test were presented to the network. The average MAPE value was 10.3 %. The last 6 months MAPE value was 12% in the product group selection.

After all the variables were analyzed by ANN, the same data was used for regression. SPSS software was used in the regression. Based on the collinearity values, the input variables included in the model are Consumer confidence index, interest rate, car production and Euro currencies. The MAPE value has been 6.22 for the last 7 months.

ANN was used again with the inputs used in the regression. All the steps in the first step are repeated in order. The appropriate learning and momentum coefficients are 0.8 and 0.3, the number of iterations is 4000, the number of neurons is 9, and the number of layers is 3. The MAPE value was 4.91% when tested with data from the last 7 months.

Using more than one method improves the outcomes. When the regressions MAPE value and the first ANNs MAPE value are compared with the MAPE values of the second ANN, the estimation performance was observed to increase.



1. GİRİŞ

Otomotiv sektörü üretim, istihdam, küresel ticaretteki pay olarak dünyanın önde gelen iktisadi faaliyet kollarından biridir. Dünyada otomotiv sektörü küresel firmaların güdümünde faaliyet göstermektedir. Maliyet, yatırıma uygunluk, kaynaklara yakınlık gibi etkenlere göre değerlendirilerek üretim yeri seçimleri; dünyanın herhangi bir yeri olarak karar verilebilir.

Türkiyede otomotiv sektörü 1950li yılların ortalarında üretime başlanmıştır. 1960ların ortalarında yatırımlar artmıştır. 2002 yılı ve sonrasında ise üretimde ciddi artışlar olmuştur. Sektör bugün olduğu gibi gelecekte de ekonomideki hayati önemini koruyacaktır. [1]

Otomotiv sektörü ülkenin siyasi istikrarı, eğitim durumu, kişi başına düşen milli gelir, enflasyon, faiz oranları gibi bir çok makroekonomik değişkene bağımlıdır. [2]

Üretim hacminin yüksek olması, üretim girdilerinin çok çeşitli olması, lokasyonların farklı olması; artan rekabet koşullarında etkin tedarik zinciri yönetimine dikkat çekmeye başlamıştır. Tedarik zincirinin etkin yönetimi ile karlılıklar arasındaki bağlantı ön plana çıkmaktadır.

Tedarik zinciri yönetiminde en önemli aşama planlamadır. Etkin bir planlama ise talep tahminlerine dayanmaktadır. Talep tahminleri kısa-orta-uzun vadeli tahminler olmak üzere işletmelerin kısa-orta vadeli operasyonel planlamalarına, uzun vadeli stratejik planlamalarına girdi oluşturmaktadır. Vade uzadıkça talebe etki eden değişkenlerin sayısı artmaktadır, vade kısaldıkça da tahminin doğruluk derecesinin önemi artmaktadır.

1.1 Tezin Amacı

Bu çalışmada amaç yüksek talep değişkenliğine sahip bir ürün grubunun talep tahmininde kullanılacak sayısal bir model geliştirmektir. Bu amaçla otomotiv yan sanayinde faaliyet gösteren bir işletmenin ürünleri arasında en fazla talep değişkenliğine sahip ürün grubu belirlenmiş ve model bu ürün grubuna bağlı olarak geliştirilmiştir. Geliştirilen modelle sektörün dinamikliğine, değişkenliğine uyum

sağlayabilecek bir talep tahmin yöntemi kurularak isabetli tahminler üretilmeye çalışılacaktır. Böylece tahminlerin tutarsızlığının yarattığı satınalma, tedarik planlama, üretim ve kapasite planlama aşamalarında yaşanan aksaklıkların önüne geçilmesi amaçlanmaktadır. Tahmini yapılacak ürünün seçimi için 6 aylık satış verileri ve tahmin doğrulukları kullanılmıştır. 32 aylık geçmiş dönem verisi kullanılarak uygun bir YSA (Yapay Sinir Ağı) kurgulanacaktır. Daha sonra regresyon yapılacak, regresyondaki doğrusallık ilişkilerine göre dikkate alınan girdilerle tekrar bir YSA çalışılacaktır. Sonuçlar karşılaştırılacaktır. Böylece gelecek dönemlere ait tahminler yapılabilecek, tahmin çalışmalarının doğruluk oranları arttırılacak, tutarsız tahminlerin sebep olduğu olumsuz sonuçlardan işletmenin korunması sağlanmış olacaktır.

1.2 Tez Planı

İkinci bölümde tedarik zinciri yönetimi ve önemi, otomotiv sektörü, sektörün Dünyada ve Türkiye’de gelişimi, talep tahmini konularında bilgiler verilecektir.

Üçüncü bölümde tahmin yöntemleri açıklanacaktır.

Dördüncü bölümde talep tahmin çalışmaları, Yapay Sinir Ağları (YSA)nın kullanıldığı çalışmalar ve otomotiv sektöründe tahmin amaçlı YSA kullanılan çalışmalar hakkında bilgi verilecektir.

Beşinci bölümde çalışmada kullanılan yapay sinir ağları tekniği hakkında tanımı, yapısı, çalışma mantığı gibi bilgiler verilecektir.


Altıncı bölümde ise uygulamaya geçilecektir. Son 6 aylık satış verileri ve talep tahminleri kullanılarak talep tahmin edilecek malzeme seçilecektir. Daha sonra son 32 aylık GSYİH (Gayrisafi Yurtiçi Hasıla), taşıt kredisi faizi, tüketici güven endeksi (TGE), reel kesim güven endeksi (RGE), Benzin fiyatı, Dolar kuru, Euro kuru, Türkiyedeki aylık otomobil üretimi, aylık yerli üretim otomobil satışı değerleri girdi ve ürün satışı çıktı olarak kullanılarak uygun YSA yapısı belirlenecektir. Test işlemlerinden sonra gelecek dönemler için tahminler yapılacaktır. Aynı girdi değişkenleri ile regresyon çalışması yapılacaktır. Regresyonda dikkate alınan değişkenler ile tekrar YSA çalışılacaktır. 3 yöntemin sonuçları karşılaştırılacaktır.

Son bölümde de çalışmalar değerlendirilerek ileride yapılabilecek çalışmalar hakkında öneriler sunulacaktır.


2. TEDARİK ZİNCİRİ YÖNETİMİ

1980ler boyunca üreticiler üretim verimliliklerini arttırmak için Tam Zamanında Üretim (TZU), Toplam Kalite Yönetimi (TKY) gibi teknikler kullandılar. Daha sonra müşterilerin ihtiyaçlarını karşılamak için daha özel ürünlere ve hizmetlere ihtiyaçları vardı. Siparişe üretim yapan işletmeler daha küçük lot büyüklüklerinin ve daha kısa teslim zamanlarının artan baskısı altındaydılar. Sonuç olarak da esneklik, düşük maliyet, yüksek kalite ve verimli küçük lot üretimleri hızla gerçekleştirilmeliydi. Bunlara cevap verebilmek için organizasyonlar satın alma fonksiyonlarını kurumsal bütünleşik bir planlama sistemine yükseltme gereği ortaya çıktı. Satın alma ve tedarik yönetimini diğer fonksiyonlarla da entegre etmek üretim prosesleriyle yakın bir ilişki kurulmasını sağladı. Bu da organizasyonlara iç ve dış müşterilere zamanında efektif şekilde ürün ve hizmet sağlanmasını sağladı. Bu yeni entegrasyonun adımları literatürde farklı isimlerle anıldı. Tedarik zinciri yönetimi ise hammadde tedariğinden son ürüne hatta geri dönüşüme kadar tüm adımları kapsamaktadır. [3]

Kısaca Tedarik Zinciri Yönetimi, Tedarik zinciri yönetiminde bilgi ve malzeme akış yönleri ve ilişkilerde Şekil 2.1 ve Şekil 2.2de gösterilmiştir.[4]



Şekil 2.1 : Klasik Tedarik Zinciri Yönetimi.



Şekil 2.2 : Klasik Tedarik Zinciri Yönetimi.

Tedarik Zinciri Derneği'nin tanımına göre ilk hammadde den nihai ürünün müşterideki tüketimine kadar olan tüm süreç ve şirketin içindeki ve dışındaki ürüne değer katan müşteriye hizmet sağlayan tüm fonksiyonlardır. [5]

Tedarik Zinciri Yönetimi'nin önemi ürün ve hizmet temininde müşteriyi de bir partner olarak sürece dahil etmesindedir. Müşteriyi tedarik zinciri yönetimine dahil etmenin bazı avantajları vardır. Birincisi bu entegrasyon müşteriden tedarikçiye bilgi akışı sağlar. Bu bilgi akışı sayesinde belirsizlikler ortadan kalkar, tedarikçi üreticinin ihtiyaçlarını daha iyi analiz edebilir. Tedarikçinin stoğunu azaltmasını, tedarik süresini kısaltmasını ve böylece maliyetlerini düşürmesini sağlar. Müşteriye de daha hızlı cevap verebilir hale gelir. İkinci avantajı ürün geliştirme süreci diğer süreçlerle entegre edilebilir. Bu entegrasyon ürün geliştirme personelinin müşteriyle daha fazla iletişim kurmasını ve böylece ihtiyaçlarına daha kısa sürede cevap verebilmesini, geliştirme süresinin kısaltılmasını sağlar. Firmalar ayrıca kendi şirketleri içinde de iç müşteri kavramını kullanırlar. Bu kavram sayesinde çalışanlar sadece kendi firmalarının ihtiyaçlarına değil son müşterinin ihtiyaçlarına odaklanırlar. Böylece büyük bir tedarik zincirinin parçası olduklarını hatırlarlar. [5]

Tedarik zinciri yönetiminde bilgi akışının sağlanması stok yönetiminde daha etkili olabilmesi için müşteri ve tedarikçinin karşılıklı olarak ihtiyaç zamanları ve teslim zamanları konusunda anlaşmaları gerekmektedir. Bu da işbirlikçi bir planlama gerektirmektedir. Her gün ihtiyaç miktarları ve zamanlar konusunda karşılıklı anlaşarak planlama yapılabilmesi için firmalar İleri Planlama ve Çizelgeleme (APS) sistemleri kullanmaktadırlar. [5]

Müşteriler kısa dönemli haftalık, 2 haftalık gibi taleplerini tedarikçilere EDI (Electronic Data Interchange) ya da internet vasıtasıyla iletebilirler. Ancak tedarikçilerin planlama yapabilmek için daha uzun zamanlı taleplere ihtiyaçları vardır. Bu noktada talep tahminleri devreye girmektedir.

2.1 Otomotiv Sektörü

Otomotiv sektörü tüm sanayileşmiş ülkelerde ekonominin lokomotifi olarak kabul edilmektedir. Dünyada toplam motorlu taşıt üretiminin %70ini otomobil üretimi oluşturmaktadır. Türkiye’de de durum aynıdır. [6]

Dünyada otomotiv endüstrisi 1890larda başladı. Uzun yıllar Amerika toplam otomobil üretiminde dünyayı yönetti. 1980 yılında Japonya Amerikayı geçti.1994 yılında Amerika tekrar birinciliği eline aldı. 2012de 19.3 milyon adet üretimle Çin birinci sırada yer alırken, 10.3 milyon adetle Amerika ikinci sırada, 9.9 milyon adetle Japonya üçüncü sırada yer aldı. [7] Dünyada motorlu araç üretimi (otomobil ve ticari araç) nin yıllara göre değişimi Çizelge 2.1’de verilmiştir. Dünyada araç sayısı 1950de 50 milyon araç iken 2004te 550 milyon araca ulaştı. 2050de ise 5 milyarın üzerine çıkacağı tahmin edilmektedir. [8]

Çizelge 2.1 : Toplam motorlu taşıt üretimi.

Year	Production	Change
2000	58,374,162	3.8%
2001	56,304,925	-3.5%
2002	58,994,318	4.8%
2003	60,663,225	2.8%
2004	64,496,220	6.3%
2005	66,482,439	3.1%
2006	69,222,975	4.1%
2007	73,266,061	5.8%
2008	70,520,493	-3.7%
2009	61,791,868	-12.4%
2010	77,857,705	26.0%
2011	79,989,155	3.1%
2012	84,141,209	5.3%
2013	87,300,115	3.7%
2014	89,747,430	2.6%

2.2 Türkiye’de Otomotiv Sektörü

Türkiye’de 1954 yılında tarım alanında da kullanılmaya uygun olan Jeep modellerinin üretimi için fabrika kurulmuş ve askeri cip, kamyonet, kamyon üretimine başlanmıştır. 1955te ticari kamyonet ve kamyon üretimine başlanmıştır. 1959 yılında Ford Motor Company ve Koç grubu Otosanı kurmuş ve otomobil üretimine yönelik ilk adımı atmışlardır. 1968 yılında Tofaş, 1969 yılında da Oyak kurulmuştur. 1990lı yıllarda ilk yerli üretim Opel ve Toyota markalı araçlar üretilmiştir. 1997 yılında da ilk yerli üretim olarak Honda Civic ve Hyundai Accent modelleri üretilmeye başlanmıştır. [9]

2.3 Otomotiv Sektöründe Tedarik Zinciri Yönetimi

Motorlu taşıt aracı farklı malzeme yapısı, üretim tipi, teknolojisi olan 5000 civarında parçadan oluşmaktadır. [6] Tüm parçaların bir otomotiv ana sanayi firmasında üretilmesi mümkün değildir. Her bir parçanın farklı seçeneklerinin olması, ürün çeşitliliği, yatırım ihtiyaçları ana sanayilerin ihtiyaçlarını karşılamak için yan sanayi firmalarının doğmasına neden olmuştur. Ana sanayi ve yan sanayi firmalarının ticari, teknik ve üretim kapasitesi olarak birbirlerine bağımlılığı mevcuttur.

Ana sanayi firmaları parçaların tedariği için yansanayi firmalarıyla anlaşmalar yaparlar. Süreç fiyat teklif talebiyle başlamaktadır. Yan sanayilerin tekliflerini iletmeleriyle anlaşma süreçleri başlamaktadır. Anlaşmalar sağlandıktan sonra tedarik zinciri yönetimi adına firmalar yan sanayilerden aylık, çeyreklik, yıllık bazda talep öngörülerini ileterek kapasite teyitleri isterler. Teyitler de alındıktan sonra seri üretim koşullarının sağlanması için firmalara kısa dönemli kesin ihtiyaçlarını iletmek için EDI sistemleri kurulur ya da talepler web üzerinden iletilir. Yan sanayi firmaları da bu talep miktarlarına göre üretim planlarını, malzeme/iş gücü planlarını yaparlar. Kısa dönemli ihtiyaç öngörülerini kesin olmakla birlikte bulunan zamanda maksimum 2 haftaya kadar kesin siparişlerdir. Yan sanayilerin ise üretim planlarını yapıp, dar boğazlarını keşfedip, önceden tedbir alabilmesi için, kendi malzeme/işçi ihtiyaçlarını belirlemesi için daha uzun dönemli ihtiyaç öngörülerine ihtiyacı vardır. Bu noktada talep tahmin yöntemlerine başvurulmaktadır.

2.4 Talep Tahminin Önemi

Talep tahmini en önemli iş faaliyetidir çünkü diğer tüm faaliyetleri yönlendirir. Hangi pazar takip edilecek, ne kadar stok tutulacak, hangi ürünler üretilecek, ne kadar işçi alınacak tüm bu kararlar talep tahminlerinden beslenirler. Tahmin ve planlama çok yakından ilişkili iki eylemdir. Planlama tahminlerin ışığında alınacak aksiyonları seçme sürecidir. Zayıf tahmin, kötü planlamaya yol açar. Bu da istenmeyen, hazırlıksız olunan durumlara yol açar. Satış kaybı ya da istenmeyen, aşırı stoğa sebep olur. [10]

2.5 Talep Tahminin Aşamaları


Ürünün talebine etki eden iç ve dış faktörler belirlendikten sonra , tahmin yöntemi seçilir ve öncül tahminler yapılır. Daha sonra bu tahminlerin tutarlığı izlenir ve tahmin yöntemi geliştirilir. Tahminleme yöntemleri kalitatif ve kantitatif olarak iki gruba ayrılır. Yöntemin seçiminde zaman aralığı, tahmin hazırlamak için varolan süre, verilecek kararların uzun ya da kısa vadeli oluşu, verilere erişebilme, verilerin kalitesi, yöntemi uygulayacak bireylerin özellikleri, tolere edilebilecek hata payı gibi bir çok faktör gözönünde bulundurulmalıdır. [11]



3. TAHMİN YÖNTEMLERİ

Kalitatif yöntemler; yargılara, görüşlere, sezgilere, duygu veya kişisel deneyimlere dayanır. Herhangi bir matematiksel hesaplamaya dayanmazlar. Kantitatif yöntemler ise matematiksel modellere dayanırlar.

Kalitatif yöntemlerin avantajı içerideki ve çevresel son değişiklikleri tahminlere dahil edebilir, dezavantajı ise tahminler önyargılı olabilir ve doğruluğu azalabilir. Kantitatif yöntemlerin avantajı tutarlı ve objektiftir, daha fazla bilgi göz önünde bulundurulabilir. Dezavantajı ise nicel veri elde olmayabilir, nicel verinin doğruluğuna bağlıdır. [12] Yöntemlerin şeması Şekil 3.1 de gösterilmiştir.[13]



Şekil 3.1 : Talep tahmin yöntemleri.

3.1 Kalitatif Yöntemler

Kalitatif yöntemler durumun belirgin olmadığı, çok az veri olduğu durumlarda (yeni ürün,yeni teknoloji) ya da sezgi/tecrübe gerektiren durumda kullanılırlar. Dörde

ayrılırlar. Yönetici görüşü, satış çalışanlarının tahmini, Delphi metodu, tüketici araştırmasıdır. Yönetici görüşü, yüksek seviye yöneticileri içeren küçük bir grubun görüşlerini alan yöntemdir. Diğer yöntemlere göre ürün tahmini haricinde en fazla kullanılan yöntemdir. Satış çalışanlarının tahmini, müşteriye en yakın kişiler oldukları için pazarın geleceği hakkında görüşleri etkili olabilir. Delphi metodu, uzmanlara bir panel üzerinden pazarın geleceği ya da var olan durumlar hakkında bir takım sorular yönetilmesiyle uygulanır. Tüketici araştırması, şirketlerin kendi pazar araştırmalarını tüketicilerle telefon, kişisel görüşme ya da anketlerle yürütmesidir. [14]

3.2 Kantitatif Yöntemler

Karma (nedensel) yöntemler ve zaman serileri olarak iki gruba ayrılırlar. Karma yöntemler kaynaktan alınan verilerle tahmin edilmeye çalışılan veriler arasındaki ilişkiden faydalanır. Zaman serileri yönteminde geçmişteki gerçekleşen değerlerin benzer şekilde devam edeceği öngörülür.

3.2.1 Zaman serileri

Zaman serisi belli olayların gözlem değerlerinin zamana göre sıralanışı ile elde edilen serilerdir. Zaman serisi analizi de belirli zaman aralığında gözlemlenen olay hakkında serinin yapısını veren stokastik süreci modellemeyi ve geçmiş değerlerle geleceğe yönelik tahmin yapılmasını sağlayan metottur. [15]

Zaman serisinde deterministik ya da stokastik özelliklerin dikkate alınması önemlidir. Deterministik özellikler sabit katsayı, mevsimsellik ve trendin varlığını gösterirken; stokastik özellikler serinin durağan olup olmadığını gösterir. Zaman serisi verilerinin belirli bir zaman diliminde sürekli artma ya da azalma göstermeyip, bir doğru etrafında dağılım göstermesi serisinin durağanlığını gösterir.

3.2.1.1 Basit yöntemler

En çok kullanılan en son gerçekleşen değer gelecekteki dönemin tahmini olarak alınmasıdır. Eller bir eğri çizilerek bu eğrinin tahminleri üretmek için geleceğe yansıtılması diğer bir yöntemdir. Diğer bir yöntem de geçmiş dönem verilerinin ikiye bölünerek değerlerin ortalamasının alınması ve bu ortalama değerlerin geleceğe genişletilmesi ile tahmin elde edilmesidir. [16]

Basit hareketli ortalama yöntemi: Mevsimsellik yoksa bu yöntemden faydalanılabilir. Seçilen dönem kadar gerçekleşen değerlerin ortalaması alınarak bir sonraki dönemin tahmini olarak alınır. Bu yöntemde önemli olan doğru zaman uzunluğunu seçmektir. Hesaplanışı denklem 3.1’de gösterilmiştir. [16]

$$F_t = \frac{A_{t-1} + A_{t-2} + A_{t-3} + \dots + A_{t-n}}{n} \quad (3.1)$$

Ağırlıklı hareketli ortalama: Her dönemin gerçekleşen değerine bir ağırlık değeri atanmasıyla elde edilen tahminlerdir. Ağırlıkların seçimi deneme, yanılma, tecrübe yöntemleri ile belirlenir. Genel kural en yakın geçmişteki değer, gelecek hakkındaki en iyi göstergedir ve daha yüksek ağırlıklıdır. Ağırlıkların toplamının bir olması gereklidir. [16]

$$F_t = w_1 A_{t-1} + w_2 A_{t-2} + w_3 A_{t-3} + \dots + w_n A_{t-n} \quad (3.2)$$

3.2.1.2 Üstel düzeltme

Üstel düzeltme yöntemi verilerdeki değişimlerin dikkate alınarak tahminlerin sürekli güncellendiği yöntemlerdir. Yakın geçmişte gerçekleşen değerlerin geleceğe etkisinin daha yüksek olacağı varsayımı ile tahminde bulunurken yakın geçmiş değerlerinin ağırlığı daha yüksek yapılır. Yöntem verilerin özelliklerine göre farklı yöntemlerden oluşmaktadır. Tekli üstel düzeltme yöntemi, Brown’un tek parametrelili doğrusal üstel düzeltme yöntemi, Holt’un iki parametrelili doğrusal üstel düzeltme yöntemi, basit mevsimsel üstel düzeltme yöntemi ve Holt-Winters’in mevsimsel üstel düzeltme yöntemi yöntemlerden bazılarıdır. Trend olmayan ve mevsimsel bileşenin zaman içerisinde sabit olduğu serilerde basit mevsimsel düzeltme, trend ve mevsimsel etkiler içeren serilerin tahmininde ise Holt-Winters mevsimsel düzeltme yöntemi kullanımı uygundur. [17]

3.2.1.3 Box-Jenkins yöntemi

Zaman serileri kesikli, doğrusal ve stokastik süreç içerirse Box-Jenkins veya ARIMA modeli olarak adlandırılmaktadır. Otoregresif (AR-Auto-Regressive) ve hareketli ortalama (MA-Moving Average) modellerinin karışımı olan Otoregresif Hareketli Ortalama (ARMA-Auto Regressive Moving Average) modelleri en genel doğrusal durağan Box-Jenkins modelleridir. Durağan olmayıp fark alma işlemi ile durağanlaştırılan serilere uygulanan modeller Birleştirilmiş Otoregresif Hareketli Ortalama (ARIMA-Auto Regressive Integrated Moving Average) modeli olarak adlandırılır. ARIMA modeli Box-Jenkins tekniği olarak da adlandırılır. Yöntemde

amaç zaman serisine en iyi uyan ve en az parametre içeren doğrusal modelin belirlenmesidir. Dört adımdan oluşur. Bu adımlar belirleme, parametre tahmini, uygunluk testi ve öngörüdür. [18]

3.2.1.4 Trend analizi

Geçmiş veriler kullanılarak değişim kalıplarının keşfedilmeye çalışıldığı yöntemdir. Gelecekte de aynı şekilde devam edeceğini varsayar. Seriyeye en uygun trend doğrusu bulunmaya çalışılır.

3.2.2 Karma (Nedensel) yöntemler

Karma yöntemler kaynaktan alınan verilerle tahmin edilmeye çalışılan veriler arasındaki ilişkiden faydalanır.

3.2.2.1 Regresyon analizi

Regresyon değişkenler arasındaki ilişkiyi inceler, ilişkinin matematiksel fonksiyonunun bulunmasını sağlar. İlişkinin matematiksel fonksiyonunun ortaya çıkarılmasıyla birlikte yönü ve derecesi de diğer bir araştırma konusudur. Bu noktada da korelasyon kavramı ortaya çıkmaktadır. Korelasyon ise bir değişken değişirken diğerinin değişip değişmediğini, değişiyorsa ne yönde değiştiği ve değişimin derecesini ortaya çıkarır. [19]

Basit regresyon: Tek bir bağımsız değişken içeren regresyon modelidir. Y bağımlı değişkeni ve X bağımsız değişkeninin olduğu durumda, gerçekte iki değişken arasındaki ilişkiyi veren iktisadi fonksiyon $Y_t = \alpha + \beta X_t$ iken tahmin edilen ilişki fonksiyonu $Y_t = a + bX_t$ dir. İlgili doğrunun kesim noktasını veren değer a iken eğimini veren değer b dir. Bu değerlerin bulunması için kullanılacak yöntem en küçük kareler yöntemidir. Yöntemin esası a ve b değerlerini hata terimlerinin tahminleri arasındaki farkın karelerinin toplamı minimum olacak şekilde seçmektir. [19]

Çoklu regresyon: Bağımlı değişkenin birden fazla bağımsız değişken tarafından etkilendiği durumda kullanılır. Tahmin edilecek olan regresyon doğrusu iki bağımsız değişkenin olduğu durumda $Y_t = a + bX_t + cZ_t$ halini alır. Y deki değişimler kısmen X kısmen Z deki değişimlerden kaynaklanmaktadır. Burada b Z sabitken Y nin X e göre değişimini veren katsayı, c ise X sabitken Y nin Z ye göre değişimini veren katsayıdır. [19]

3.2.3 Yapay zeka sezgisel modeller

Genetik algoritma: Günümüzün karmaşık ve zor problemlerine daha kolay ve kısa zamanda çözüm almak için evrimsel algoritma kullanımları ön plana çıkmıştır. Genetik algoritma popülasyon temelli sezgisel bir yöntemdir. Altdizi kavramıyla arama yapılmaktadır. Dizi kümeleri arasındaki benzerlik altdizilerle tanımlanır. Eğer bir H dizisi tanımlanırsa ve o kalıba uyan bir x altdizisi mevcutsa, x dizisi için H 'ın örneğidir denir. Alt dizilerin dereceleri ve uzunlukları vardır. Dereceleri $o(H)$ şeklinde, uzunluğu ise $\delta(H)$ olarak ifade edilir. Derecesi düşük, uzunluğu kısa olan diziler yapı blokları olarak tanımlanır. Popülasyonun ortalaması üzerinde olan derecesi düşük, uzunluğu kısa diziler zamanla üssel olarak çoğalırlar. Uygulamanın yapısı kötüye gidişi engellemekte ve hızlı bir iyiye gidiş sağlamaktadır. Çözüm uzayındaki her nokta kromozom olarak kodlanır. Tek nokta yerine popülasyon olarak noktalar kümesi muhafaza edilir. Her kuşakta çaprazlama, mutasyon gibi genetik operatörlerle yeni bir popülasyon oluşturulur. Birkaç kuşak sonunda popülasyon daha iyi uygunluk değerine sahip üyeleri içerir. [20]

Genetik algoritmalarda problemin başarısına etki eden en önemli faktör bireylerin gösterimidir. Başlangıç çözümü genellikle rastgele oluşturulur. Çaprazlama ve mutasyonla elde edilen yeni çözümlerin uygunluk değerleri hesaplanır. Aday çözümün uyum değeri ne kadar iyiye sonrakı popülasyonlarda yaşama olasılığı o kadar yüksektir. [21]

Algoritmanın adımları aşağıdaki gibidir:

Başlangıç: n adet kromozom içeren toplum oluşturulması ve problemin ikilik sistemde kodlanması,

Uygunluk: Her x kromozomu için uygunluk değerinin belirlenmesi,

Yeni toplum: Yeni toplum oluşana kadar şu adımlar tekrarlanır. Seçim adımında iki ebeveyn kromozom uygunluk değerlerine göre seçilir. Çaprazlama adımında ebeveynler çaprazlama olasılığına göre çaprazlanır ve yeni birey oluşturulur. Mutasyon adımında yeni ferdin mutasyon olasılığına göre kromozom içindeki konumu değiştirilir. Ekleme adımı ile yeni birey yeni topluma eklenir.

Değiştirme: Algoritmanın yeniden çalıştırılmasında yeni toplum kullanılır.

Test: Eğer sonuçlar tatmin edici ise algoritma sonlandırılır ve son toplum çözüm olarak sunulur. Eğer tatmin edici değilse uygunluk adımına geri dönlür. [22]

Optimizasyon problemlerinde, bilgisayar programlarının geliştirilmesinde, gözlenmiş bir veri takımının anlaşılması, yorumlanması ve özelliklerinin tahmin edilmesinde, değişkenler arasındaki ilişkilerin tespit edilmesinde kullanılırlar. İşletmelerde de kaynak tahsisi, atölye çizelgeleme, makine parça gruplama gibi çeşitli alanlarda kullanılırlar. [20]

Yapay sinir ağları:İnsan beyninin fonksiyonlarından esinlenen YSA, deneme yolu ile öğrenme ve genelleştirme yapabilmektedir. Kendisine verilen bir girdi seti ile bir çıktı seti arasında ilişki kurabilir. Veriler arasındaki farkedilmesi güç ilişkileri ortaya çıkarabilir. Tahmin, sınıflandırma problemlerinde kullanılan doğrusal olmayan modellerdir. Çalışma mantığı ve detayları daha sonraki kısımda anlatılacaktır.

3.3 Tahmin Yöntemlerinin Sonuçlarının Değerlendirilmesi

Tahmin yöntemlerinin hiçbirisi %100 doğru sonuç vermez. Geleceği %100 doğru bilmenin imkanı olsaydı tahmin yöntemlerine ihtiyaç olmazdı. Bu sebeple her tahminde bir hata payı vardır. Tahmin yöntemlerinin sonuçlarını değerlendirmenin en önemli kriteri tahmin doğruluğudur. Tahmin doğruluğu hataların analizi ile oluşturulur. Tahmin hatası tahmin edilen değer ile gerçekleşen değer arasındaki farktır. Denklem 3.3' te gösterildiği üzere e_t tahmin hatasıdır. A_t gerçekleşen değer, F_t ise tahmin edilen değerdir. Pozitif hata tahminin gerçek değerinin altında kaldığını, negatif hata ise yüksek tahmin yapıldığını gösterir.

$$e_t = A_t - F_t \quad (3.3)$$

En çok kullanılan tahmin doğruluğu ölçüm yöntemleri şunlardır:

3.3.1 Ortalama hata kareleri (MSE)

Hataları karesini alarak işaretlerden arındırır, sadece büyüklüklerine bakar. Değerlendirmede sıklıkla kullanılır.

$$MSE = \frac{\sum_{t=1}^n (A_t - F_t)^2}{n} \quad (3.4)$$

3.3.2 Ortalama mutlak hata (MAE)

Hataları mutlak olarak işaretten arındırır. Tahminin gerçek değere uzaklığına bakar.

$$MAE = \frac{\sum_{t=1}^n |A_t - F_t|}{n} \quad (3.5)$$

3.3.3 Ortalama mutlak yüzde hata (MAPE)

Hataların yüzdesini alır, hataların birbiriyle kıyaslanmasını sağlar.

$$MAPE = 100 \frac{\sum_{t=1}^n \frac{|At - Ft|}{At}}{n} \quad (3.6)$$





4. LİTERATÜR ARAŞTIRMASI

Bu bölümde YSA ile yapılan talep tahmin çalışmalarından ve otomotiv sektöründe yapılan talep tahmin çalışmalarından bahsedilecektir.

4.1 YSA ile Tahmin Çalışmaları

Es ve diğerleri (2004), YSA ile Türkiye'nin 2011-2025 yılları arasındaki net enerji talebini tahmin etmişlerdir. 1970-2010 yılları arasında GSYH, nüfus, ithalat, ihracat, bina yüz ölçümü, taşıt sayısı değişkenleri girdi olarak kullanılmıştır. Çoklu regresyona göre daha doğru sonuçlar gözlenmiştir. [23]

Hamzaçebi, Kutay (2004) Box-Jenkins, regresyon, YSA teknikleri ile Türkiye'nin 2010 yılına kadarki elektrik tüketimini tahmin etmişlerdir. Girdi değişkenlerinin nüfus ve yıl olduğu, çıktı değişkeninin tüketim olduğu iki ayrı model için, iki ayrı ağ yapısı (Geri Yayılım Ağ, Radyal Tabanlı Fonksiyon Ağı) ile çalışılmış ve sonuçlar karşılaştırılmıştır. YSA'nın daha iyi sonuçlar verdiği gözlenmiştir. [24]

Çuhadar ve Güngör (2005), Antalyayı ziyaret edecek Alman turistlerin sayısını YSA ile tahmin etmişlerdir. Ocak 1994 ve Temmuz 2004 arasındaki verileri kullanarak 2005 ve 2006 yılları için aylık tahmi yapmışlardır. Aylık ziyaret eden turist sayısı, Türkiye'deki ve Almanya'daki TÜFE değerleri, döviz kurları, kişi başına harcanabilir net milli gelir değişkenleri kullanılmıştır. Regresyona göre YSA daha düşük sapma değerleri vermiştir. [25]

Çuhadar ve Kayacan (2005) Türkiye'deki konaklama işletmelerinde dış turizm kaynaklı doluluk oranlarını tahmin etmişlerdir. 1990-2002 yılları arasında doluluk oranları istatistikleri kullanılmıştır. Türkiye'deki bakanlık onaylı tesislerin aylık sayısı, aylık yatak sayıları, konaklayan aylık yabancı turist sayıları, konaklayan yabancı turistlerin aylık toplam geceleme sayısı, ortalama kalış süreleri girdi değişkenleri olarak kullanılmıştır. Sonuçlar MSE, RMSE, MAPE değerlerine göre değerlendirilmiştir. Witt ve Witt'in MAPE değerleri %10 altındaki modellerin "yüksek doğruluk" derecesinde, %10-%20 arasındaki değerler için de doğru tahmin olarak sınıflandırıldığını belirtmişlerdir. Ayrıca Lewis'in de MAPE değeri %10

altındaki modeller için “çok iyi”, %10-%20 arası için “iyi”, %20-%50 arası için “kabul edilebilir” %50 üzeri için ise “yanlış,hatalı” olarak gruplandığını belirtmişlerdir. Bu oranlardan yola çıkarak çalışmanın sonucunda MAPE değeri %4,7 olduğu için yüksek doğruluktadır denebilir. [26]

Wu, Hsieh ve Tang (2006) Pasifik deniz yüzeyi sıcaklığını tahmin etmek için YSA kullanmışlardır. 5 ayrı gösterge için 3-6-9-12-15 aylık öncü sürelerde tahminler yapılmıştır. Yapay sinir ağlarının çapraz korelasyon becerileri genellikle Lineer Regresyona göre daha iyi çıkmıştır. [27]

Fabbian, Dear ve Lelleyett (2007) çalışmalarında Avustralya’nın başkenti Canberra şehrindeki havaalanı için YSA ile sis tahmini yapmışlardır. 3 saatlik ve saatlik gözlemlerden oluşan iki ayrı datasetinden sis sezonunun Nisan-Ağustos ayları arasında olduğu çıkarılmıştır. Sıcaklık, rüzgar hızı, basınç, rüzgar yönü, toplam bulut sayısı, görüş mesafesi, yağış miktarı girdileri kullanılmıştır. Yerel saat ile 6 için 3,6,12,18 saat sonrası olmak üzere 4 ayrı modelle tahminler yapılmıştır. Hepsi içi başarılı tahminler elde edilmiştir. [28]

Hasgöl ve Önder (2009) 1986-2007 yılları arasında Türkiye’ye gelen turist sayılarını kullanarak 2008-2010 yılları için tahminleme yapmışlardır. Zaman serisi yöntemleri, Box-Jenkins ve YSA kullanılıp sonuçları karşılaştırmışlardır. Benzer sonuçlar vermişlerdir. YSA daha düşük değerler vermiştir. [29]

Chen ve Lie(2010) Sıcaklık değişimlerinin elektrik tüketimi talebi üzerindeki etkisini YSA ile analiz etmişlerdir. 1997-2008 arasındaki fiili elektrik tüketimleri incelenmiştir. 2 yıllık, 1 yıllık, 6 aylık, 2 haftalık ayrı ayrı 4 tahmin yapılmıştır. En iyi sonuç bir yıllık tahmin için alınmıştır. 2 yıllık ve 6 aylık tahminler için de RMSE değeri %5 altında kaldığı için başarılı sonuç alınmıştır. 2 haftalık tahminde RMSE değeri %7 gibi çıkmıştır. Haftalık ya da saatlik geçmiş veriler kullanıldığında daha iyi sonuç alınacağı belirtilmiştir. Ayrıca sıcaklık değişimleri ile talebin değişimleri de analiz edilmiştir. [30]

Kaynar ve diğerleri (2010) ham petrol fiyatlarını tahmin etmişlerdir. Ocak 1986 ve Nisan 2009 arasındaki fiyatlar kullanılmıştır. SARIMA ve Çok Katmanlı İleri Beslemeli ve Radyal Tabanlı Fonksiyon ağlarını kullanan YSA yöntemleri kullanılmıştır. En iyi sonuç ve Radyal Tabanlı Fonksiyon ile alınmıştır. [31]

Özkan (2012), döviz kuru tahmini için Parasal model ve YSA kullanmıştır. Dolar için 1986-2010, Avro için 1999-2010 yılları arasında kur değerleri alınmıştır. Yerli ve yabancı ülkeye ait milli gelir, para arzı, enflasyon, faiz oranı gibi ekonomik değiş-

kenler girdi olarak kullanılmıştır. MSE, MAPE, MAE değerleri karşılaştırıldığında YSA'nın daha iyi sonuç verdiği gözlenmiştir. [32]

Hernandez ve diğ. (2013) İspanyada 2008-2010 yılları arasındaki çıktı değişkeni elektrik tüketimi ve girdi değişkenleri aynı dönemdeki hava sıcaklığı, rüzgar hızı, yönü, yağış miktarı, güneş ışınımı gibi değişkenlerle haftanın günü kullanılarak farklı modellerle sonuçlar analiz edilmiştir. [33]

Claveria ve diğerleri (2014) Katalonya'ya 2001-2012 yılları arasında farklı ülkelerden gelen turist sayılarını kullanarak 3 ayrı YSA tekniğini değerlendirmişlerdir. Sonuçları RMSE ve MAPE değerlerine göre değerlendirmişlerdir. Çok Katmanlı İleri Beslemeli, Radyal Tabanlı Fonksiyon, Elman Network kullanmışlardır. Çok Katmanlı İleri Beslemeli ve Radyal Tabanlı ağlar, Elman networka göre daha üstün çıkmıştır. Çok katmanlı ve radial tabanlı arasında karşılaştırma yapıldığında ise radyal tabanlı ağa ek gecikme verilmediğinde çok katmanlıya göre daha iyi sonuç vermektedir. Girdiler geçmişe uygun ise çok katmanlı daha iyi sonuç vermektedir. Önceki aylardaki veriler arttıkça daha uzun ufuklar için tahminlerin iyileştiği ve uzun dönemli tahmin için ağların boyutsallığının artırılmasının önemini ortaya koymuşlardır. [34]

Akdağ (2016) çalışmasında Yapay Sinir Ağları (ANN), Destek Vektör Makineleri(SVM) ve Box-Jenkins metodlarıyla Diyarbakır ilinin kentsel içmesuyu talebini tahmin etmeye çalışmıştır. 2002-2013 yılları arasındaki verileri kullanmıştır. Diğer yöntemlere göre YSA daha iyi sonuç vermiştir. [35]

Aliahmadi ve diğerleri (2016) İran'da 2006-2012 yılları arasındaki toplam verimlilik tahmini için Lineer Regresyon ve YSA kullanmışlardır. Veri olarak 1979-2005 yılları arasındaki işgücü verimliliği, üretim verimliliği, işyeri verimliliği girdileri ve toplam verimlilik çıktısını kullanarak tahmin yapmışlardır. Sonuçları RMSE, MAPE, MSE değerlerine göre değerlendirmişlerdir. Regresyon ve YSA arasında çok büyük farklar olmamasına rağmen YSA daha iyi sonuç vermiştir. [36]

Ertuğrul ve Bekin (2016) çalışmalarında buğday, arpa, çeltik fiyatlarını tahmin etmişlerdir. Holt üstel düzleştirme, ARIMA, YSA uygulamışlardır. Hata oranları (MSE) karşılaştırmış, YSA'nın daha iyi sonuç verdiği gözlenmiştir. [37]

Mladenovic, Milovancevic vd (2016) YSA ile ekonomik büyüme oranını tahmin etmişlerdir. Girdi değişkenleri hizmette ticaret, ürün ve hizmetlerde ithalat, ürün ve hizmetlerde ihracat, ticaret, mal ticareti oranları olmuştur. İleri öğrenme (ELM), geri beslemeli öğrenme algoritmaları ile denemeler yapılmıştır. 28 Avrupa Birliği ülkesinin verileri kullanılmıştır. ELM öğrenme algoritması ile daha iyi sonuçlar alınmıştır. [38]

4.2 Otomotiv Sektöründe Talep Tahmin Çalışmaları

Alper (2000) Türkiye otomotiv sektörünün 1996-1999 yılları arasında durumu analiz edilmiş, talep tahmin fonksiyonu oluşturulmuş ve 2005 yılı için talep tahmini yapılmıştır. 120 ayrı marka ve modelin fiyat, satış, kalite ve teknik özelliklerinden yararlanılmıştır. Ayrıca reel faiz, tüketici kredileri, enflasyon gibi ekonomik değişkenler de kullanılmıştır. Talebin fiyat esnekliği analiz edilmiştir. Regresyon kullanılarak talep tahmini yapılmıştır. Regresyonda GSYİH, 1000 kişi başına düşen binek otomobil sayısı, Gini endeksi kullanılmıştır. [39]

Asilkan ve Irmak (2009) ikinci el otomobillerin gelecekteki fiyatlarının tahmini için YSA kullanmışlardır. Avrupa’da ikinci el otomobil ilanı yayınlayan 40 web sitesinden veriler toplanmıştır. En popüler 3 modelin, 1 yaşındaki ve 20000 km deki ilanlarının Ocak 2005 ve Aralık 2007 arasındaki satış fiyatları kullanılmıştır. Zaman serisi yöntemlerinde ARIMA, Winters yöntemleri ile başarılı sonuçlar elde edilmiştir. Sonuçlar YSA ile karşılaştırılmıştır. YSA’nın daha başarılı sonuçlar verdiği gözlenmiştir. [40]

Gaojun ve Boxue (2009) otomobil satışı tahmini için ağırlık dağılımına göre eğri regresyon modeli, zaman serileri ayrıştırma modeli ve radyal bazlı fonksiyon yapay sinir ağlarını kombine ederek kullanmışlardır. Ocak 2005- Mart 2009 arasındaki fiili satış verileri kullanılmıştır. Lineer modellerin sonuçları ve lineer olmayan model sonuçları toplanarak tahmin öngörüsü elde edilmiştir. 2008-2009 arası için gerçekleşen değerlerle tahmin değerleri karşılaştırılmıştır. Başarılı sonuç alınmıştır. [41]

İşeri ve Karlık (2009) teknik ve fiziksel özelliklerini girdi olarak, fiyatı çıktı olarak kullanarak otomobiller için fiyat tahmini amaçlı YSA kullanmışlardır. Aracın risk değerini ifade eden sembol, yıllık sigorta masrafı, ön tekerlek arka tekerlek arası mesafe, uzunluk, genişlik, yükseklik, ağırlık, motor hacmi, silindir çapı, vuruş, sıkıştırma oranı, beygir gücü, şehir içi tüketim, şehirdışı tüketim, maksimum dönüş hızı girdi değişkenleri, fiyat çıktı değişkenidir. Mutlak hata %8 çıkmıştır. YSA başarılı tahmin yapmıştır. [42]

Yazıcıoğlu (2010) yüksek lisans tezinde YSA ile talep tahmin çalışması yapmıştır. Mart 2001 Haziran 2009 arası veriler kullanılmıştır. IMKB 100 Endeksi, Tefe-Tüfe oranları, işsizlik oranları, Türkiyeden yapılan otomobil ihracatı, Türkiyedeki otomobil ithalatı, Merkez Bankası gecelik faiz oranları, döviz kuru, Gayri Safi Yurtiçi Hasıla, Türkiyedeki ham petrol varil fiyatları, Türkiyedeki binek otomobil üretim miktarları

girdi olarak kullanılmıştır. Hedef hata %1 olarak belirlenmiştir. Eğitim hatası %0,5, test hatası %0,6 bulunmuştur. Gerçek değerlerden sapma %2 olmuştur. Regresyonla yapılan tahminde ise hata oranı %25i bulunmuştur. [43]

Wang, Chang, Tzeng (2011) Tayvan’da yeni araç satışlarını tahmin etmek için uyarlamalı ağ tabanlı bulanık çıkarım sistemi (ANFIS) kullanmıştır. Şimdiki satış miktarları, rastgele göstergeler, öncü göstergeler, toptan eşya fiyat endeksi, gelir, döviz kuru gibi değişkenler göz önünde bulundurulmuştur. Tedadüfi göstergeler: Endüstriyel üretim endeksi, gümrükten çekilen gerçek ihracatlar, üretim satışları, toptan-perakende ve gıda hizmetleri satış endeksi, gerçek makine ve elektrikli cihaz ihracatları, tarım dışı istihdam, toplam enerji tüketimidir. Öncü göstergeler: ortalama aylık mesai, ihracat endeksi, kentleşme ve oturma izinlerinin yüzeysel ölçümü, üreticilerin envanter endeksleri, hisse senedi fiyat endeksidir. Toptan eşya fiyat endeksi göstergeleri: otomobil fiyatları, benzin fiyatları, otomobil parçaları fiyatlarıdır. Bağımsız göstergeler: nüfus, işsizlik oranı, ortalama gelirdir. Regresyon ile girdi değişkenleri içinde en çok etkili olanları seçilmiştir. En çok etkili olan değişkenler ortalama gelir, üretici envanter endeksi, benzin fiyatları, kentleşme ve oturma izni çıkmıştır. En çok etkili olan değişkenler ve satışlar kullanılarak uyarlanabilir ağ tabanlı bulanık çıkarım sistemi (ANFIS) ile tahmin yapılmıştır. Sonuçlar ARIMA ve YSA ile karşılaştırılmıştır. ANFISin diğer ikisinden daha iyi sonuç verdiği gözlenmiştir. [44]

Karaatlı ve diğerleri (2012) otomobil satışlarının tahmininde Yapay Sinir Ağlarını kullanmışlardır. Ocak 2007 ve Haziran 2011 arasındaki aylık verileri kullanmışlardır. Girdi değişkenleri olarak Gayrisafi Yurtiçi Hasıla (GSYH), reel kesim güven endeksi, yatırım harcamaları, tüketim harcamaları, tüketici güven endeksi, dolar kuru ve zaman, çıktı değişkeni için ise satılan toplam otomobil sayısı kullanılmıştır. Verilerin %80i eğitim, %20si test verisi olarak kullanılmıştır. Sonuçlar değerlendirilirken RMSE, MSE, MAPE değerlerine bakılmıştır. Çok katmanlı ağ kullanılmıştır. MAPE değeri %16,82 çıktığı için çalışma doğru tahmin grubuna girmiştir. [12]

Sa-ngasoongsong ve diğerleri (2012) Amerikadaki Ocak 1975 ve Aralık 2010daki iki ayrı segment için (büyük ve küçük) sıfır araç satış verilerini ve ekonomik değişkenleri kullanmışlardır. Ekonomik indikatörülerin satışa etkileri Hata Düzeltme tekniği ile analiz edilmiştir. Tüketici fiyat endeksi, işsizlik oranı, benzin fiyatları, kentleşme indikatörleri seçilmiştir. Değişkenlerin durağanlığının testi için birim kök testi uygulanmıştır. Durağan olup olmamalarına göre eşbütünleşme testleri uygulanmıştır. İşsizlik ve kentleşmedeki artışın büyük araç satışına negatif etki ettiği görülmüştür.

Tüketici fiyat endeksinin ve işsizlik oranının ise satışa ve diğer ekonomik indikatörlere etkisinin zayıf olduğu ortaya çıkmıştır. [45]

Kitapçı ve diğerleri (2014) 2005 ve 2010 yılları arasındaki euro kuru, enflasyon, otomobil ve benzin fiyatları, reklam harcamaları, GSYİH, araç kredisi değerlerini girdi değişkeni olarak kullanarak YSA ve çok aşamalı regresyon yöntemini kullanarak araç satışlarını tahmin etmişlerdir. Enflasyon, faiz oranlarının ve euro kurunun satışlara direk etki ettiği sonucunu çıkarmışlardır. YSA'da MAPE değeri %18 olmuşken, regresyonda %54 olmuştur. YSA daha iyi sonuç vermiştir. [46]

Akyurt (2015) Ocak 2011-Eylül 2015 arasındaki yerli otomobil satışlarını kullanarak orjinal veriler ve mevsimsel etkilerden arındırılmış veriler olmak üzere iki ayrı veri seti ile YSA yöntemini kullanarak talep tahmini yapmıştır. Değerlendirme için MAPE ve MSE yöntemleri kullanılmıştır. Mevsimsel etkilerden arındırılmış veri seti ile yapılan tahminler de MAPE ve MSE değerleri daha düşük çıkmıştır. [47]

Kuvvetli ve diğerleri (2015) araç segmenti, markası, geçmiş satış verileri, taşıt kredileri faiz oranı, gayrisafi milli hasıla, CO2 emisyonu, yakıt tüketim miktarları ve fiyat parametrelerinin girdi değişkenleri, satışların çıktı değişkeni olarak kullanıldığı YSA modeliyle 2008-2012 yılları arası için araç satış tahmini yapmışlardır. Regresyon yöntemi ile de tahmin yapmışlardır. Sonuçları regresyon değeri ve hata kareleri ortalamaları ile değerlendirmişler ve YSA'nın daha iyi sonuç verdiğini ortaya koymuşlardır. [48]

Karaca (2015) araç talep tahmin çalışması içeren Yüksek Lisans tezinde 2013-2014 yıllarında Türkiye'de satılmış olan otomobile ve hafif ticari araç verilerini kullanarak 6 aylık tahminler yapmıştır. Verilerin SAAR yöntemiyle mevsimsel etkilerden arındırılmış halleri ile de çalışma yapmıştır. Zaman serisi yöntemleri, Regresyon yöntemleri, YSA ve destek vektör makineleri ile tahminler yapılmıştır. Otomobil satışları için en iyi yöntem regresyon ve YSA olurken, hafif ticari araçlar için holt-winter zaman serisi yöntemleri daha iyi sonuç vermiştir. [49]

Matsumoto ve Ikeda (2015) otomotiv parçalarının yeniden üretimi için zaman serileri yöntemiyle talep tahmini uygulaması yapmışlardır. Ürün iadeleri, zamanlama ve miktar bakımından son derece belirsizdir. İmalatçıların stok birikmemesi için ve geri dönen taleplerin karşılanamamasını önlemek için yeniden üretilmiş ürünlerle ilgili talep dengelenmesi gerekmektedir. 400 tip yeniden üretilmiş alternator ve marşın 11 yıllık verileri kullanılmıştır. 10 yıl için hareketli ortalama, son 1 yıl için çift üstel düzeltme yönteminden Holt metodu ile tahmin yapılmıştır. Hata oranı %27,2 çıkmıştır. [50]

Rodrigues ve diğerleri (2015) bir firmada stok maliyetlerini azaltmak için uygulanan tahmin yönteminden farklı tahmin metodları ile talep tahminleri yapıp sonuçları değerlendirmişlerdir. Basit Ortalama, Hareketli Ortalama, Holt, Basit Üstel Düzeltme yöntemlerini uygulamışlardır. En iyi sonuç hareketli ortalamalar yöntemiyle alınmıştır. Ortalama hata %1,47 çıkmış ve stok maliyeti %63 azaltılmıştır. [51]

Lolli, Gamberini vd. (2017) çalışmalarında kesikli talep örneğinin otomotiv sektöründe yedek parça talebinin tahmini için YSA kullanmışlardır. Yapı olarak ileri beslemeli, gecikmeli, dönüşümlü; öğrenme algoritması olarak geri yayımlı (BP), ileri öğrenme (ELM), öğrenme modu olarak da online ve yığın modlarını içeren farklı ağlar oluşturulmuştur. Bir, üç ve beş dönem ilerisi için test yapılmıştır. 24 haftalık data seti ile çalışılmıştır. Tekrarlayan ANOVA testi yapılmıştır. Yapılan testler sonucunda geri yayılım algoritmasının, ileri öğrenme algoritmasından daha verimli sonuçlar verdiği gözlenmiştir. [52]

No	Yazar (Yıl)	Uygulanan Teknik	Kullanılan Program	Uygulama Alanı	Ağ Yapısı	Aktivasyon Fonksiyonu	Değişken Sayısı	Öğrenme Fonksiyonu	Dönem birimi	Veri Sayısı
1	Es vd (2014)	YSA, Regresyon	MATLAB	Enerji Talebi Tahmini	İleri Beslemeli Geri Yayılım (FFBPN)	Sigmoid	6	Learningdm	Yıl	40
2	Hamzaçebi, Kutay (2004)	YSA, Regresyon, Box-Jenkins	MATLAB, Minitab	Elektrik Talebi	Radyal Tabanlı Fonksiyon (RBFN), Geri Yayılım (BPN)	Hiperbolik Tanjant	1	Powell-Beale	Yıl	32
3	Çuhadar, Güngör (2005)	YSA, Regresyon	MATLAB	Alman Turist Sayısı Tahmini	İleri Beslemeli Geri Yayılım (FFBPN)	Logsig	5	Trainlm	Ay	163
4	Çuhadar, Kayacan (2005)	YSA	MATLAB	Otel Doluluk Oranı Tahmini	İleri Beslemeli Geri Yayılım (FFBPN)	Sigmoid	5	Trainlm	Ay	144
5	Wu, Hsieh ve Tang (2006)	YSA	MATLAB	Deniz yüzeyi sıcaklığı tahmini	FFMLP	-	2	Trainbr	Ay	672
6	Fabbian, Dear ve Lelliyett (2007)	YSA	MATLAB	Havaalanında sis tahmini	MLP	-	8	Trainlm	Gün	15794
7	Hasgöl ve Önder (2009)	YSA, Box-Jenkins, Üstel Düzgünleştirme	Excel, SPSS, Qnet	Yabancı Ziyaretçi Sayısı Tahmini	Geri Yayılım (BPN)	-	2	Learningdm	Ay	262
8	Chen ve Lie (2010)	YSA	MATLAB	Elektrik Tüketimi Tahmini	İleri Beslemeli Geri Yayılım (FFBPN)	-	11	-	Gün	3600
9	Kaynar ve diğerleri (2010)	ARIMA, YSA	MATLAB	Hampetrol Fiyatı Tahmini	MLP, RBF	-	1	-	Ay	268
10	Özkan (2012)	YSA	MATLAB	Dolar ve Euro Kuru Tahmini	Geri Yayılım (BPN)	-	8	-	Ay	338-132
11	Claveria ve diğerleri (2014)	YSA	MATLAB	Turist Sayısı Tahmini	MLP, RBF, Elman	-	2	Learningdm	Ay	139
12	Akdağ (2016)	YSA, DVM, Box-Jenkins	Alyuda Neurointelligence	İçme suyu Talebi Tahmini	İleri Beslemeli Geri Yayılım (FFBPN)	Sigmoid	10	Hızlı yayılım	Ay	120
13	Alahmadi ve diğerleri (2016)	YSA, Lineer Regresyon	SPSS, MATLAB	Verimlilik Tahmini	Geri Yayılım (BPN)	Hiperbolik Tanjant	3	-	Yıl	27

Şekil 4.1 : Literatür özeti.

No	Yazar (Yıl)	Uygulanan Teknik	Kullanılan Program	Uygulama Alanı	Ağ Yapısı	Aktivasyon Fonksiyonu	Değişken Sayısı	Öğrenme Fonksiyonu	Dönem birimi	Veri Sayısı
14	Ertuğrul ve Bekin (2016)	YSA, Box-Jenkins, Üstel Düzgünleştirme	MATLAB	Temel Gıda Fiyat Tahmini	FFMLP	Sigmoid	1	LM	Ay	168
15	Mladenovic, Milovancevic vd (2016)	YSA	-	Ekonomik Büyüme Oranı Tahmini	İleri Beslemeli (FFN)	Sigmoid	5	BP, ELM	Yıl	28
16	Asilkan ve Irmak (2009)	YSA, ARIMA, Winters	SPSS, Clementin	İkinci El Otomobil Fiyat Tahmini	Geri Yayılım (BPN)	Hiperbolik Tanjant	1	BP	Ay	36
17	Gaojun ve Boxue (2009)	YSA	-	Otomobil Satış Tahmini	Radyal Tabanlı Fonksiyon (RBFN)	-	1	-	Ay	50
18	İşeri ve Karlık (2009)	YSA	MATLAB	Özelliklerine göre Otomobil Fiyat Tahmini	MLP, BP	-	15	LM	-	159
19	Yazıcıoğlu (2010)	YSA, Regresyon	EasyNN, Minitab	Otomobil Talep Tahmini	Geri Yayılım (BPN)	Sigmoid	11	Learningdm	Ay	100
20	Wang, Chang, Tzeng (2011)	ANFIS, ARIMA, YSA	-	Otomobil Talep Tahmini	-	-	22	-	Ay	77
21	Karaatlı ve diğerleri (2012)	YSA	MATLAB	Otomobil Talep Tahmini	MLP	-	7	-	Ay	54
22	Kitapçı ve diğerleri (2014)	YSA, Regresyon	MATLAB	Otomobil Talep Tahmini	-	-	7	-	Ay	60
23	Akyurt (2015)	YSA	R	Yerli Otomobil Satış Tahmini	İleri Beslemeli Geri Yayılım (FFBPN)	Sigmoid	1	-	Ay	56
24	Kuwetli ve diğerleri (2015)	YSA	MATLAB	Otomobil Talep Tahmini	İleri Beslemeli (FFN)	-	10	LM	Ay	48
25	Karaca (2015)	YSA	R-AMORE	Otomobil Talep Tahmini	-	-	6	-	Ay	144
26	Lolli, Gamberini vd. (2017)	YSA, Regresyon	Neurosolution, MATLAB	Yedek Parça Tahmini	İleri Beslemeli, Gecikmeli, Dönüşümlü	-	1	BP-ELM, learningdm	Hafta	24

Şekil 4.2 : Literatür özeti devam.

5. METOD

5.1 Yapay Sinir Ağları


Çalışmanın bu bölümünde Yapay Sinir Ağlarının tanımı, çalışma mantığı, tarihsel gelişimi, modelleri konularında bilgiler verilecektir.

5.1.1 Yapay sinir ağları tanımı

Bilgisayarlar ve teknoloji geliştikçe bilgisayarların yaptığı işlerin boyutları da değişmiştir. Olaylar karşısında karar verebilme ve olayların arasındaki ilişkileri öğrenebilmektedirler. Bilgisayarların bu özelliklere kavuşmasını sağlayan çalışmalara yapay zeka uygulamaları denilmektedir. Yapay zeka uygulamalarına örnek olarak bulanık mantık, genetik algoritma, yapay sinir ağları verilebilir. Yapay Sinir Ağları insan beyninin çalışma mantığından yola çıkılarak geliştirilmiştir.

Biyolojik sinir sistemini taklit eden, insanlardaki sinir hücrelerinin benzetimini yapan; öğrenme, öğrendiklerini hafızasında tutma, genelleme ya pma gibi insani özellikleri taklit edebilen bir sistemdir. Paralel çalışma özelliği sayesinde çok kısa zamanda sonuçlar üretebilmekte, gerçek problemlerin çözümünde faydalı sonuçlar verebilmektedirler. İstatistiksel yöntemlerden ayrılan temel özelliği, verilerin istatistiksel dağılımı hakkında varsayım yapmamasıdır. Doğrusal olmayan bir tahmin yöntemi olduğundan karmaşık verilerin modellemesinden daha iyi sonuçlar vermektedir. [53]

Yapay sinir ağının en küçük birimine sinir hücresi denilmektedir. Şekil 5.1 'de görüldüğü gibi girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere 5 bileşenden oluşmaktadır. [54]



Şekil 5.1 : Yapay Sinir Ağlarının yapısı.

Yapay sinir ağı, nöronların birbirleri ile ağırlıklar vasıtası ile çeşitli şekillerde bağlanmasından oluşur. Ağ ayrıca bu nöron bağlantılarının oluşturduğu katmanlar şeklinde sıralanır. Beynin öğrenme sürecine uygun olarak YSA, bir öğrenme algoritması eşliğinde kendisine sunulan veriyi derleme, bu verilerden bir çıkarım yapma, öğrenmiş olduğu bu çıkarımı nöronlar arasındaki ağırlıklar vasıtası ile saklama ve bunu tüm veri uzayı için genelleme yetisine sahip bir işlemci olarak gösterilebilir. [55]

5.1.2 Yapay Sinir Ağlarının genel özellikleri

Geliştirilmiş olan her modelin kendisine özgü özellikleri olabileceği gibi Yapay Sinir Ağlarının genel özelliklerine aşağıda değinilecektir. [56] [57]

Doğrusal olmayan yapı: YSA'ların en önemli özelliklerinden birisi gerçek hayattaki olası doğrusal olmayan yapıları da dikkate alabilmesidir. Ekonomik verilerin doğrusal olmayan bir yapıda olmaları normaldir ancak tahmin zorlukları nedeniyle çalışmalar lineer yöntemlerle yapılmaktadır. Bu durum olası bir doğrusal olmama durumunda yanlış sonuçlara yol açmaktadır. YSAnın doğrusal olmayan yapıları da dikkate alıyor olması önemli bir özelliğidir.

Öğrenme: İnsan beyninin çalışma sisteminden uyarlanan bu yöntem sayesinde geleneksel teknikler için çok karmaşık olanlar problemler çözülebilmektedir. Eğitim aşaması sayesinde verileri kullanarak öğrenme yeteneğine sahiptir. Ağa bilgilerin detaylı olarak gösterilmesi ağın başarısı için önemlidir.

Bilginin saklanması: Bilgi ağı bağlantılarının değerleri ile ölçülmekte ve bağlantılarda saklanmaktadır. Diğer programlardaki gibi veri tabanında ya da programın içinde gömülü olmadığı için ortaya çıkarılması ve yorumlanması zordur.

Yerel İşlem ve Esneklik: Geleneksel işlemcilerde tek bir merkez tüm işlemleri sırasıyla yaparken, YSAda her biri büyük problemin bir parçasıyla ilgilenen çok sayıda küçük işlemci bulunmaktadır. Bağlantı ağırlıklarının ayarlanabilmesi sayesinde de önemli bir esnekliğe sahiptir.

Genelleme ve Hata toleransı: Ağ kendisine verilen örnekleri kullanarak görmediği örnekler hakkında da çözümler üretebilir. Eksik ya da hatalı veri olması durumunda da sonuç verebilirler. Eksik veri durumu sadece performansını etkileyebilir o da kayıp bilginin önemine bağlıdır. Eğer önemsiz bir bilgi ise verdiği sonuçlar değişmeyecektir.

Kendi ilişkisini oluşturma: Ağ verilen bilgiler sayesinde kendi ilişkilerini kendisi kurar. Bir denklem içermez. Sistemin için ne olduğu tam olarak analiz edilemez.

Sınırsız sayıda değişken ve parametre: Sistem sınırsız sayıda değişken ve parametre ile çalışabilir. Verilen verilerin çeşitliliği ağı öğrenmesi açısından daha avantajlıdır. Değişkenlerin her biri gerektiği anda gerektiği kadar kullanılacak şekilde eğitilebilirler.

Dereceli bozulma: Ağlar hatalara karşı toleranslı olduklarından dereceli olarak bozulurlar. Bu eksik bilgi ya da hücrelerin bozulmasından kaynaklıdır. Herhangi bir problem ortaya çıktığında anında bozulmazlar.

Numerik bilgilerle çalışma: Yapay sinir ağları sadece numeric bilgilerle çalışabilmektedir.

5.1.3 Yapay Sinir Ağlarının dezavantajları

Yapay sinir ağları paralel çalışabilme özelliklerine karşın makineler çoğunlukla seri çalışırlar ve aynı zamanda sadece tek bir bilgiyi işleyebilirler. Paralel işlemleri seri makinelerde yapmak zaman kaybına sebep olmaktadır.

Probleme uygun ağ yapısının belirlenebilmesi deneme yanılma yoluyla yapılabilmektedir. Uygun ağ yapısı belirlenemezse problemin çözümü mümkün olmayabilir ya da performansı düşük çözümler elde edilebilir. Optimum çözümü garanti etmez.

Bazı ağılarda ağın parametre değerlerinin belirlenmesinin kuralı olmaması da diğer bir problemidir. İyi çözümler bulmayı zorlaştırmaktadır. Her problem için ayrı faktörlerin dikkate alınmasını gerektirir.

Ağı öğrenileceği problemin ağa gösterimi önemli bir problemidir. Sadece numeric değerlerle çalışabildiğinden problemin numeric hale getirilmesi gereklidir. Uygun bir gösterim mekanizması kurulamazsa problem çözülemeyebilir ya da performansı düşük sonuçlar üretebilir.

Ağı eğitiminin ne zaman bitirileceği konusunda bir yöntem yoktur. Ağı örnekler üzerindeki hatasının belli bir seviyenin altına çekilmesi öğrenme için yeterli görülmektedir. Ancak optimum çözüm garantisi yoktur, sadece en iyi çözümler üretebilen bir ağ geliştiği söylenebilir.

Ağı davranışları açıklanamamaktadır. Bir probleme çözüm üretildiğinde bunun nasıl ve neden üretildiğine yönelik bilgi bulma imkanı yoktur.

5.1.4 Yapay Sinir Ağlarının uygulama alanları

Başarılı uygulamalar incelendiğinde yapay sinir ağlarının doğrusal olmayan, çok boyutlu, gürültülü, karmaşık, kesin olmayan, eksik, kusurlu, hata olasılığı yüksek verilerinin olması ve problemin çözümü için bir matematiksel modelin bulunmaması hallerinde yaygın olarak kullanıldıkları görülmektedir. Genellikle aşağıdaki fonksiyonları yerine getirmektedirler: [56]

- Sınıflandırma
- İlişkilendirme
- Zaman serileri analizleri
- Sinyal filtreleme
- Veri sıkıştırma
- Örüntü tanıma
- Doğrusal olmayan sinyal işleme
- Doğrusal olmayan system modelleme
- Optimizasyon

Daha önce yapılmış çalışmalardan yola çıkılarak derlenmiş önemli uygulama alanları ise aşağıdaki gibi sıralanabilir: [58]

Arıza analizi ve tespiti: Bir sistemin, cihazın düzenli çalışma koşullarını öğrenen YSA sayesinde arızaların tahmini mümkündür. Elektrikli makinelerin, uçakların ya da devrelerin hata analizlerinin tespiti için kullanılmaktadır.

Tıp alanında: Tıbbi sinyallerin analizi, kanser hücrelerinin tespiti, hastane giderlerinin optimizasyonu gibi alanlarda kullanılmaktadır.

Savunma sanayi: Silahların otomasyonu, hedef takip, nesne ve görüntüleri tanımlama gibi amaçla yönelik kullanılmaktadır.

Haberleşme: Görüntü/veri sıkıştırma, otomatik bilgi sunma uygulamaları gibi alanlarda kullanımları mevcuttur.

Üretim: Üretim sistemleri optimizasyonu, ürün analizi ve tasarımı, kalite analizi, yönetim alanlarında YSA kullanımlarına rastlanmaktadır.

Otomasyon ve kontrol: Otomatik pilot sistemi, otomatik yol bulma, elektrikli sürücü sistemleri kontrolü alanlarında YSA uygulanmaktadır.

İstatistik: Klasik istatistik yöntemleri yerine regresyon ve kümeleme analizi alanlarında YSA kullanımı oldukça geniştir.

Finans: Borsa endeksi, enflasyon tahmini, ülkelerin finansal durumlarına göre gruplandırılması, kredi kartı hilelerinin tespiti, kredi değerlendirme, döviz kuru tahmini gibi alanlarda YSA kullanılmaktadır.

5.1.5 Yapay Sinir Ağlarının tarihsel gelişimi

Yapay Sinir Ağlarının tarihçesi insanların nörobiyoloji konusuna ilgi duymaları ve sonuçları bilgisayar bilimine uygulamaları ile başlamaktadır. Bu çalışmalar aşağıdaki şekilde özetlenebilir: [59]

- 1890: İnsan beyninin yapısı ve fonksiyonları ile ilgili ilk yayının yazılması
- 1911: İnsan beyninin bileşenlerinin belirli bir düzenek ile sinir hücrelerinden oluştuğu fikrinin benimsenmesi
- 1943: Yapay Sinir hücrelerine dayalı hesaplama teorisinin ortaya atılması: Warren McCulloch/Walter tarafından Pitts “Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap” teorisi ortaya atılmıştır.
- 1949: Biyolojik olarak mümkün olabilen öğrenme prosedürlerinin bilgisayarlar tarafından gerçekleştirilecek biçimde geliştirilmesi: Hebb Kuralı.
- 1956-1962: Adaline ve Windrow öğrenme algoritmasının geliştirilmesi.
- 1957-1962: Tek Katmanlı Algılayıcının (Perceptron) geliştirilmesi.
- 1965: İlk makine öğrenme kitabının yazılması.

- 1967-1969: Bazı gelişmiş öğrenme algoritmalarının geliştirilmesi: Grosberg öğrenme algoritması.
- 1969: Tek katmanlı algılayıcıların problemleri çözme yeteneklerinin olmadığını gösterilmesi.
- 1969-1972: Çağrışımlı Bellek (Associative memory) konusunda çalışmalar: Kohonen ve Anderson çalışmaları.
- 1969-1972: Doğrusal İlişkilendiricilerin geliştirilmesi.
- 1972: Korelasyon ve matriks belleğinin geliştirilmesi.
- 1974: Geri Yayılım modelinin (Çok katmanlı algılayıcıların ilk çalışmaları) geliştirilmesi.
- 1978: Öğretmensiz Öğrenmenin geliştirilmesi ART Modeli.
- 1982: Öğretmensiz Öğrenme; Kohonen Öğrenmesi ve SOM modelinin geliştirilmesi.
- 1982: Hopfield Ağlarının ve Çok Katmanlı algılayıcılarının geliştirilmesi.
- 1984 Boltzman makinesinin geliştirilmesi.
- 1985: Çok katmanlı algılayıcıların Genelleştirilmiş Delta Öğrenme Kuralı ile geliştirilmesi.
- 1988: RBF modelinin geliştirilmesi.
- 1988: PNN modelinin geliştirilmesi.
- 1991: GRNN modelinin geliştirilmesi.
- 1991den günümüze kadar da sayısız çalışmalar yapılmıştır.


5.1.6 Yapay Sinir Ağları ile Diğer Yöntemlerin Karşılaştırılması

Yapay sinir ağları ilişkileri kendisi öğrendiğinden uzman sistemlerdeki bilgi toplama problem ortadan kalkmaktadır ancak burada problemdeki ilişkileri doğru temsil eden verilerin ağı öğretilmesi önemlidir. Yapay sinir ağlarının geleneksel tekniklerinden farkları Çizelge 5.1 de görülmektedir. [60]

Çizelge 5.1 : Geleneksel yöntemler ve YSA karşılaştırma.

	Geleneksel Teknikler	Yapay Sinir Ağları
Öğrenme Süresi	-	Uzun
Cevap verme Süresi	Uzun	Kısa
Öncelikli bilgi	Gerekli	Sadece örnekler gerekli
Bilgi Temsili	Zor	Kolay
Rasgele seçilmiş problem	Zor	Kolay
Performans	Uygun	İyi
Bilgi İşleme	Açık	Kapalı
Kaynak	Uzman Kişi	Örnekler

Geleneksel tekniklerle Yapay Sinir Ağlarının işlem süreci açısından karşılaştırılması ise Şekil 5.2.de gösterilmiştir.[61] İki yöntem arasındaki ana farklılık veri işlemi yöntemidir. Geleneksel metotta veri yönteme bir defada verilmekte iken YSA'da tekrar tekrar verilerek iteratif şekilde öğrenmesi sağlanmaktadır.



Şekil 5.2 : Geleneksel yöntemlerle ve YSA ile tahmin süreci karşılaştırma.

Yapılan uygulamalarda yapay sinir ağlarının ve uzman sistemlerin her biri kendi uzmanlık alanındaki işi yapmak üzere bir araya gelerek oluşturduğu sistemlerin daha iyi sonuçlar vereceği ortaya koyulmaktadır. Oluşturulan bu sistemlere hibrit (karma) sistemler denilmektedir. Uzman sistemler ve Yapay sinir ağlarının farklı yönleri bir araya gelerek birbirlerinin eksiklerini gidererek daha güçlü bir system oluşturmaktadırlar. Uzman sistemler ve Yapay Sinir Ağlarının karşılaştırılması Çizelge 5.2. de verilmiştir.[60]

Çizelge 5.2 : Uzman Sistemler ve Yapay Sinir Ağlarının karşılaştırılması.

Parametre	Uzman Sistemler	Yapay Sinir Ağları
Kullanıcı arabirimi	Mevcuttur	Mevcut değildir
Açıklama yeteneği	Mevcuttur	Mevcut değildir
Uzman Kişi	İhtiyacı vardır	İhtiyacı yoktur
Örnekler	İhtiyacı yoktur	İhtiyacı vardır
Problemin boyutu çoğaldığında bakım	Zorlaşır	Değişmemektedir
Oluşturulması	Kurallar, Hiyerarşik yapılar	Eğitilmekte
Bilgi İşleme	Seri ve Karmaşık	Paralel
Bilgi Temsili	Kesin ve açık/ Sözlü ifade	Saklı / sözlü ve sayısal ifade
Tam değerlerin belli olması	Şarttır	Şart değildir

5.1.7 Yapay Sinir Ağlarının bileşenleri

5.1.7.1 Yapay sinir hücresi

Yapay sinir hücresi, yapay sinir ağlarını oluşturan en temel birimdir. Yapay sinir hücreleri aralarında bir bağlantı kurularak katmanlar halinde sıralanmasıyla yapay sinir ağları oluşur. Yapay sinir ağları metodolojisine göre sinir hücreleri matematiksel olarak modellenenirler ve birbirleriyle ilişkilendirilebilirler. Bir yapay sinir ağına dışarıdan veri girişi yapıldığında biyolojik sinir sisteminde olduğu gibi bilgiyi işleyip çıktılar üretebilirler.

Yapay sinir hücresi 5 bileşenden oluşmaktadır. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılardır. [61]

5.1.7.2 Girdiler

Bir yapay sinir hücresine dış dünyadan verilen bilgilerdir. Bir yapay sinir hücresine başka sinir hücresinden ya da kendisinden de bilgi gelebilir. [56]

5.1.7.3 Ağırlıklar

Bir yapay hücreye gelen bilginin önemini ve etkisini ifade ederler. Artı veya eksi olması etkisinin negatif yada pozitif olduğunu gösterir. Sıfır olması etkisinin olmadığını gösterir. [56]

Ağırlığın değerinin büyük olması o girişin yapay sinire güçlü bağlanması veya önemli olması; küçük olması ise güçlü bağlanmaması ya da önemsiz olması anlamına gelmemektedir. [62]

5.1.7.4 Toplama fonksiyonu

Bu fonksiyon hücreye gelen net girdiyi hesaplar. Bunun için değişik fonksiyonlar kullanılmaktadır. En yaygın kullanılanı ağırlıklı toplamı bulmaktır. Her gelen girdi kendi ağırlığı ile çarpılarak toplanır. Toplama fonksiyonu örnekleri Çizelge 5.3.de gösterilmiştir. [56]

Çizelge 5.3 : Toplama fonksiyonları.

Net Giriş	Açıklama
Çarpım $Net\ Girdi = \prod_{i=1}^N G_i A_i$	Ağırlık değerleri, girdiler ile çarpılır ve daha sonra bulunan değerler birbirleri ile çarpılarak net girdi hesaplanır.
Maksimum $Net\ Girdi = \max(G_i A_i), i=1...N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en büyüğü yapay sinir hücresinin net girdisi olarak kabul edilebilir.
Minimum $Net\ Girdi = \min(G_i A_i), i=1...N$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra en küçüğü yapay sinir hücresinin net girdisi olarak kabul edilebilir.
Çoğunluk $Net\ Girdi = \sum_{i=1}^N sgn(G_i A_i)$	N adet girdi içinden ağırlıklar ile çarpıldıktan sonra pozitif ve negatif olanların sayısı bulunur. Büyük olan sayı, hücrenin net girdisi olarak kabul edilebilir.
Kümülatif Toplam $Net\ Girdi = Net\ (eski) + \sum_{i=1}^N G_i A_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi hesaplanır.

5.1.7.5 Aktivasyon fonksiyonu

Aktivasyon fonksiyonu, toplama fonksiyonundan gelen girdiyi işleyerek yapay sinir hücresinin çıkışı belirler. Transfer fonksiyonu olarak da adlandırılan aktivasyon fonksiyonu çeşitli tiplerde olabilir. Genellikle doğrusal olmayan fonksiyonlardır. Doğrusal fonksiyonlarda girdi ve çıktı doğru orantılı olacağından doğrusal fonksiyon tercih edilmez. İlk yapay sinir ağı denemelerinin başarısızlıkla sonuçlanmasının temel nedeni doğrusal fonksiyon seçimidir. [63]

Aktivasyon fonksiyonu seçimi de diğer parametreler gibi deneme yanılma yoluyla yapılmaktadır. Günümüzde en yaygın olarak kullanılan çok katmanlı algılayıcı modelinde en çok kullanılan aktivasyon fonksiyonu sigmoid fonksiyonudur.

Aktivasyon fonksiyonu örnekleri Çizelge 5.4de verilmiştir. [56]

Çizelge 5.4 : Aktivasyon fonksiyonları.

Aktivasyon fonksiyonu	Açıklama
Lineer fonksiyon $F(Net)=Net$	Gelen girdiler olduğu gibi hücrenin çıkışı olarak kabul edilir.
Step fonksiyonu $F(Net)=\begin{cases} 1 & \text{if } Net > \text{eşik değeri} \\ 0 & \text{if } Net \leq \text{eşik değeri} \end{cases}$	Gelen NET girdi değerinin belirlenen eşik değerinin altında veya üstünde olmasına göre hücrenin çıkışı 1 veya 0 değerlerini alır.
Sinüs fonksiyonu $F(Net)=\sin(Net)$	Öğrenilmesi düşünülen olayların sinüs fonksiyonuna uygun dağılım gösterdiği durumlarda kullanılır.
Eşik değeri fonksiyonu $F(Net)=\begin{cases} 0 & \text{if } Net \leq 0 \\ Net & \text{if } 0 < Net < 1 \\ 1 & \text{if } Net \geq 1 \end{cases}$	Gelen bilgilerini 0 veya 1'den büyük veya küçük olmasına göre bir değer alır. Ve 1 arasında değerler alabilir. Bunların dışında değerler alamaz.
Hiperbolik tanjant fonksiyonu $F(Net)=\frac{(e^{Net}-e^{-Net})}{(e^{Net}+e^{-Net})}$	Gelen NET girdi değerinin tanjant fonksiyonundan geçirilmesi ile hesaplanır.
Sigmoid fonksiyonu $F(Net)=\frac{1}{1+e^{-Net}}$	En çok kullanılan aktivasyon fonksiyonu

5.1.7.6 Çıktılar

Aktivasyon fonksiyonu tarafından belirlenen çıktı değeridir. Bu değer ya başka bir yapay sinir hücresine girdi olarak ya da dış ortama gönderilmektedir. Bir işlemci elemanın birden fazla girdisi olmasına rağmen tek bir çıkışı olmaktadır.

5.1.8 Yapay Sinir Ağlarının yapısı ve sınıflandırılması

5.1.8.1 Katman yapısına göre sınıflandırma


Tek katmanlı YSA: Sadece girdi ve çıktı katmanından oluşan ağlardır. Basit algılayıcı (Perceptron) ve ADALINE/MADALINE modelleri bulunmaktadır. ADALINE adaptif doğrusal eleman ağının kısaltmasıdır. Bir proses elemanından oluşmuş ağdır. MADALINE ise birden fazla ADALINE ünitesinin bir araya gelerek oluşturduğu ağdır. İki modeli ayıran şey öğrenme kuralıdır. Basit algılayıcılarda ağırlıklar değiştirilirken girdiler öğrenme katsayısı ile çarpılarak ağırlıklara eklenmesi ile gerçekleştirilir. ADALINE da ise ağırlıkların değiştirilmesi beklenen çıktı ile gerçekleşen çıktı arasındaki farka göre yapılır.

Çok Katmanlı YSA :En az bir gizli katmanı olan doğrusal olmayan Yapay Sinir Ağlarıdır. Bu tip ağ yapıları, tek katmanlı ağ yapılarına göre daha karmaşık problemleri çözebilmektedir. Ancak çok katmanlı ağların eğitilmesi, tek katmanlı ağların eğitilmesine göre oldukça zordur. Buna rağmen birçok problemin çözümünde çok katmanlı ağların eğitimi, tek katmanlı ağların eğitimine göre daha başarılı olabilmektedir. Bunun nedeni, tek katmanlı ağların problemin çözümü için yetersiz kalmalarından kaynaklanmaktadır. [63]

5.1.8.2 Bağlantı yapısına göre sınıflandırma

Bağlantı yapısına göre ileri beslemeli ve geri beslemeli olarak ikiye ayrılırlar.


İleri beslemeli ağlar: İleri beslemeli Yapay Sinir Ağlarında n boyutlu girdi vektörü üzerinden ağa giriş katmanı aracılığıyla uygulanan girişler ait oldukları ağırlıkları ile çarpılarak bir sonraki katmana iletilirler. Gecikmeler olmaz ve işlemler girişten çıkışa doğru ilerler. Çıkış değerleri öğreticiden alınan istenen çıkış değerleriyle karşılaştırılarak bir hata sinyali alınır ve ağırlıklar güncellenir. Gizli katmanlardaki nöronların doğrusal olmayan davranışlarından dolayı ağın toplam davranışı da doğrusal olmaz. Veri akışı ileri yönlüdür. İleri beslemeli ağlara örnek olarak Çok Katmanlı Algılayıcılar (MLP) ve Sayısallaştırılmış Öğrenme Vektörü (LVQ) verilebilir. Şekil 5.3 de ileri beslemeli ağlara ait blok diyagramın yapısı verilmiştir. [64]



Şekil 5.3 : İleri beslemeli yapay sinir ağları yapısı.

Çok katmanlı algılayıcılar (MLP) bir giriş, bir ya da daha fazla gizli katman ve bir çıkıştan oluşurlar. Her katmanda bir veya daha fazla işlemci bulunabilir. Gizli katmandaki ara katman sayısı ve ara katmanlarda işlemci elemanlarının sayısı deneme yanılma yoluyla bulunabilir. [53]

Geri beslemeli yapay sinir ağları: Geri beslemeli yapay sinir ağlarında en az bir hücrenin çıkışı kendisine ya da diğer hücreler giriş olur. Geri besleme bir geciktirme elemanı üzerinden yapılır. Örneği Şekil 5.4de gösterilmiştir. [53] Geri besleme bir katman üzerindeki hücreler arasında olduğu gibi katmanlar arasındaki hücreler arasında da olabilir. Geri beslemenin yapısına göre farklı davranışta yapay sinir ağları elde edilebilir. Standart geri besleme algoritması katmanlar arasında tam bir bağlantının olduğu çok katmanlı, ileri beslemeli, öğreticili olarak eğitilen bir YSA modelidir. Hataları geriye doğru çıkıştan girişe azaltır. Bir geri beslemeli ağ modelinde giriş, gizli ve çıkış olmak üzere minimum üç katman bulunur. [65]



Şekil 5.4 : Geri beslemeli yapay sinir ağları yapısı.

5.1.9 Yapay sinir ağının eğitimi ve öğrenme stratejileri

Yapay sinir ağlarının yapısı insan beyninin çalışma yapısına benzer olduğu için insanın büyüme sürecinde dışardan aldığı bilgileri, olayları ve sonuçlarını gözlemleyerek öğrenmesi ve benzer durumlarda bu bilgi ve gözlemlere dayanarak davranış geliştirmesi gibi yapay sinir ağları da kendine örnekler gösterildikçe öğrenir.

Başlangıçta ağı rastgele ağırlık değerleri atanır. Amaç ağı doğru çıktıları üretmesini sağlayacak olan ağırlık değerlerinin tespit edilmesidir. Doğru ağırlık değerlerine ulaşıldığında ağ olaylar hakkında genelleme yapma yeteneğine kavuşmuş olur. Bu işleme ağı öğrenmesi denir. Ağırlık değerlerinin değiştirilmesi belli kurallara göre yapılmaktadır. Bu kurallara öğrenme kuralları denilir. [56]


Ağın eğitiminden sonra öğrenip öğrenmediğini ölçme işlemine test etme denir. Test için ağı öğrenme sırasında görmediği örnekler verilir. Eğitim sırasında belirlenen ağırlık değerleriyle çıktı üretmesi beklenir. Elde edilen çıktıların doğruluk derecesi ağı öğrenmesi hakkında bilgi verir. Genellikle eldeki verilerin %80'i ağı eğitimi için eğitim verisi olarak, kalan %20'si de testi için test verisi olarak kullanılır. Ağı bilinmeyen örnekler hakkında yorum yapabilmesine “adaptif öğrenme” denir.

Öğrenme algoritmaları danışmanlı, danışmansız ve takviyeli olarak 3 gruba ayrılır.

5.1.9.1 Danışmanlı öğrenme

Ağ eğitilirken çıktıların istenen değerleri ağı tanıtılırsa bu tür öğrenmeye danışmanlı öğrenme adı verilir. Ağ girdileri işleminden geçirerek kendi çıktısını elde eder, ve bu çıktıyı gerçek çıktı ile karşılaştırarak ağırlıklarını değiştirir. Süreç kabul edilebilir hata seviyesine inilene kadar devam eder. Eğitim setinin yapısı çok önemlidir. Modeli temsil edecek tüm özellikleri taşıması ve örnek sayısının çok olması bu yapıda önemlidir. Yapısı Şekil 5.5 de gösterildiği gibidir. [65]


Danışmanlı öğrenme kuralları, Algılayıcı öğrenme kuralı, Delta öğrenme kuralı, Genişletilmiş Delta öğrenme kuralı, Geri Yayılımlı öğrenme kuralıdır. [17]



Şekil 5.5 : Danışmanlı öğrenme yapısı.

5.1.9.2 Danışmansız öğrenme


Bu stratejide sistemin öğrenmesine yardımcı olan herhangi bir öğretmen yoktur. Sadece girdi değişkenleri gösterilir. Parametreler arasındaki ilişkileri sistemin kendisi öğrenmesi beklenir. Daha çok sınıflandırma problemlerinde kullanılır. Yapısı Şekil 5.6 daki gibidir.[63] Kohonen Ağları ve ART ağları bu stratejiyi kullanmaktadır. [56]



Şekil 5.6 : Danışmansız öğrenme yapısı.

5.1.9.3 Destekli (takviyeli) öğrenme

Ağın davranışının doğru olup olmadığını belirten bir öz yetenek bilgisine ihtiyaç duyulur. Deneme-yanılma yöntemine göre ağ eğitilmektedir. Danışmanlı öğrenmeye benzemekle birlikte ağa hedef çıktılar yerine çıktıların ne derece doğru olduğunu belirten bir skor bildirilir. [64] Yapısı Şekil 5.7de gösterilmiştir. [52] LVQ ağı bu stratejiyi kullanan ağlara örnek gösterilebilir. [56]



Şekil 5.7 : Destekli öğrenme yapısı.

Bunlar dışında yöntemlerin birlikte kullanıldığı karma yöntemler de mevcuttur. Kısmen danışmanlı, kısmen danışmansız öğrenme yapan ağlarda kullanılırlar. Radyal Tabanlı Yapay Sinir Ağları (RBN), Olasılık Tabanlı Yapay Sinir Ağları (PBN) karma öğrenme yöntemlerine örnek gösterilebilir.

5.1.10 Öğrenme kuralları

Hangi strateji kullanılırsa kullanılsın öğrenme bazı kurallara göre gerçekleşmektedir.

Çoğu Hebb kuralına dayanmaktadır. [56] [66]

Hebb kuralı: En eski öğrenme kuralıdır. Bir hücre diğer hücreden bilgi alırsa ve her iki hücrede aktif ise (matematiksel olarak aynı işaretli) iki hücre arasındaki bağlantı kuvvetlendirilir.

Hopfield kuralı: Beklenen çıktı ve girdilerin ikisi de aktif ise aradaki bağlantı öğrenme katsayısı kadar kuvvetlendirilir, pasif ise azaltılır. Öğrenme katsayısı pozitif ya da negatif bir sayısal değerdir. Öğrenme hızı 0-1 arasında seçilmektedir.

Delta kuralı: Beklenen çıktı ile gerçekleşen çıktı arasındaki farkı azaltmak için bağlantıların ağırlık değerleri sürekli değiştirilir. Aradaki hatanın karelerinin ortalamasını enazlamak hedefidir.

Kohonen kuralı: En büyük çıktıyı üreten hücre kazanan hücre olur ve kendisi ve çevresindeki hücrelerin ağırlıklarını değiştirmesine izin verilir.

5.1.11 Yapay sinir ağı çalışma yöntemi

Veri setinin toplanması: Eğitim ve test amaçlı örnek olayların toplanmasıdır. Örnekler ağa gösterilerek öğrenmesi sağlanır. Daha sonra test verileri kullanılarak ağın verdiği sonuçlar gözlenir. Görmediği olaylar karşısında verdiği çıktı ağın ne kadar iyi öğrendiğini gösterir.

Ağın topolojik yapısının belirlenmesi: Kaç girdi ünitesi olacağı, kaç ara katman olacağı, kaç ara katman, kaç çıktı işlemcisi olacağının seçilmesidir.

Öğrenme parametrelerinin belirlenmesi: Öğrenme katsayısı, elemanların toplama ve aktivasyon fonksiyonlarının, momentum katsayısının belirlenmesidir.

Ağırlıkların başlangıç değerlerinin atanması: Proses elemanlarını birbirine bağlayan ağırlık değerlerinin başlangıç değer atamaları yapılır. Daha sonra ağ öğrenme sırasında uygun ağırlıkları seçer.

Eğitim setinden örneklerin seçilmesi ve ağa gösterilmesi: Ağın öğrenmeye başlaması ve uygun ağırlık değerlerini belirlemesi için örnekler belli bir düzene göre gösterilir.

Öğrenme sırasında ileri hesaplamaların yapılması: Verilen girdiler için ağın çıktı değerlerini hesaplamasıdır.

Gerçekleşen çıktıların beklenen çıktılar ile karşılaştırılması: Ağın hata miktarları hesaplanır.

Ağırlıkların değiştirilmesi: Geri hesaplama yöntemi uygulanarak hatanın azalması için ağırlıklar değiştirilir. [56]



6. UYGULAMA

Çalışma bir otomotiv yan sanayi firmasında yapılmıştır. Çalışmada öncelikle talep tahmin modeli kurulacak olan ürün grubu ile bilgi verilmiştir. Fiili satışlar ile öngörüler arasındaki sapmalar üretim planlarında, talep karşılamalarda, malzeme tedarikinde farklı problemlere yol açmaktadır. Bu amaçla ilgili ürün grubuna yönelik talep tahmini için sayısal bir model geliştirilmeye çalışılacaktır. Böylece tahmin sapmaları minimize edilecek ve yol açtığı problemler de azaltılmış olunacaktır. Bunun için Yapay Sinir Ağları ve regresyon yöntemleriyle talep tahmini yapılacaktır.

Uygulama için öncelikli olarak bir otomotiv yan sanayi firmasının aylık satış verileri kullanılarak tahmin çalışmasında kullanılacak olan ürün grubu seçilmiştir. Daha sonra otomotiv satışlarını etkileyecek olan değişkenlerin yan sanayideki ürünün satışına da etki edeceği kabulüyle kullanılan değişkenler tanımlanmıştır. Bir sonraki aşamada Yapay Sinir Ağları değişkenlerinin optimum değerleri tespit edilmesi, tahminler yapılması ve sonuçların değerlendirilmiştir. Aynı girdi değişkenleri ile regresyon çalışması yapılmıştır. Regresyon tahminleri ve tüm girdilerle çalışılan YSA'nın test sonuçları karşılaştırılmıştır. Regresyonda eşdoğrusallık sonuçlarına göre dikkate alınan 4 girdi değişkeni ile tekrar YSA çalışılarak tahmin sonuçları regresyon ve tüm değişkenlerle elde edilen tahmin değerlerine göre iyileştirilmiştir.


6.1 Talep Tahmini Yapılacak Ürün Grubunun Seçimi

Satış hacmi toplam satışın %80'ini oluşturan grup içinden tahmin sapması yüksek bir ürün grubu seçilmiştir. Herhangi bir analitik yönteme başvurulmadan satış sorumlularının görüşleri ile yapılan tahminler ile gerçekleşen satışlara bakılarak son 6 aylık tahmin MAPE değeri ortalaması %12,1 dir.

Çizelge 6.1 : Ürün grubunun tahmin-fiili karşılaştırması.

Tahmin	Fiili	MAPE
24581	24470	0,5
24581	28832	14,7
28194	28706	1,8
20849	27488	24,2
23000	29568	22,2
25000	27639	9,5

Talebin 32 aylık değişim grafiği aşağıdaki gibidir:




Şekil 6.1 : Talebin değişimi Mayıs 2014-Aralık 2016.

6.2 Talebi Etkileyen Faktörler


Otomotiv talep tahmin çalışmalarında kullanılan faktörlerin yan sanayideki ürün satışlarını da etkileyeceği kabulüyle seçilen faktörler aşağıdaki gibidir:

- 1) Otomobil Satışları: Seçilen parçanın ait olduğu anasanayi firmasının aylık satışlarındaki değişim ilgili malzemenin satışına direkt olarak etki edecektir.




Şekil 6.2 : Otomobil satışı Mayıs 2014-Aralık 2016.

2) Otomobil Üretim Adedi: Üretim miktarı arttıkça satış miktarı da artacaktır.




Şekil 6.3 : Otomobil üretimi Mayıs 2014- Aralık 2016.

3) Gayri Safi Yurtiçi Hasıla (GSYH): Bir ülke sınırları içinde belli bir zaman diliminde üretilen tüm nihai mal ve hizmetlerin para birimi cinsinden değerini ifade etmektedir. Artması halkın alım gücünün artmasını ifade ettiği için satışları da etkileyecektir.




Şekil 6.4 : GSYH 2014-2016 arası değişimi.

4) Taşıt Kredisi Faiz Oranları: Faiz oranlarındaki değişim otomobil satışlarına etki edecektir.




Şekil 6.5 : Faiz oranlarının değişimi.

5) Euro Kuru: Euro kurundaki deęişim satış miktarlarını etkileyecektir.




Şekil 6.6 : Euro kurunun deęişimi.

6) Dolar Kuru: Dolar kurundaki deęişim satış miktarlarını etkileyecektir.




Şekil 6.7 : Dolar kurunun deęişimi.

7) Otomobil Satınalma İhtimali: TUIK sitesinden alınmış olan gelecek 12 aydaki otomobil satınalma ihtimali sonuçlarının satışlara etki edebileceęi düşünölmüştür.




Şekil 6.8 : Otomobil satınalma ihtimalinin deęişimi.

8) Benzin Fiyatı: Benzin fiyatındaki değişim satış miktarlarını etkileyecektir.




Şekil 6.9 : Benzin fiyatı değişimi.

9) Tüketici Güven Endeksi: Tüketicilerin mali durumlarını ve genel ekonominin durum değerlendirmeleri ve gelecek dönem beklentilerini, harcama ve tasarruf eğilimlerini gösteren bir göstergedir.



Şekil 6.10 : Tüketici Güven Endeksi değişimi.

10) Reel Kesim Güven Endeksi: İmalat, perakende, ticaret, inşaat sektörlerinin güven göstergelerinin ağırlıklandırılmasıyla elde edilen bir göstergedir.



Şekil 6.11 : Reel Kesim Güven Endeksi değişimi.

Veriler Otomotiv Distribütörleri Derneği, IMKB ve TUIK verilerinden derlenmiştir.

6.3 Tüm Girdi Değişkenleri ile Yapay Sinir Ağı Uygulaması

Talep tahmininde en çok kullanılan algoritma, geri yayılım algoritmasıdır. Bu nedenle çalışmada çok katmanlı ileri beslemeli geri yayılım algoritması kullanılmıştır. Mayıs 2014- Aralık 2016 arasında 32 aylık veri kullanılmıştır. Verilerin 25i ağı eğitimi, 7si testi için kullanılmıştır. Veriler Min_Max normalizasyon tekniği ile 0-1 aralığına getirilmiştir. Girdi katmanı 10 hücreden çıktı katmanı 1 hücreden oluşmaktadır. Gizli katmanda birden fazla hücre bulunabilmektedir. Eğitim fonksiyonu olarak Momentum Terimli Geri Yayılım Algoritması (traingdm), öğrenme fonksiyonu olarak da learngdm fonksiyonu kullanılmıştır. Aktivasyon fonksiyonu olarak logsig ve tansig denenmiş, logsig değerleri daha uygun olduğu için onunla devam edilmiştir. Çalışma kapsamında aşama aşama uygun eğitim katsayısı, momentum katsayısı, iterasyon sayısı, hücre sayısı ve katman sayısı bulunmuştur. Denemelerin sonuçlarında en küçük MAPE ve MSE değerlerini veren değişkenler seçilmiştir. Program olarak MATLAB R2011B programı kullanılmıştır.

6.3.1 Öğrenme katsayısı belirlenmesi

Öğrenme katsayısı ağı öğrenme performansı açısından önemlidir. Küçük değerler seçilmesi eğitimin uzun sürmesine, büyük değerler seçilmesi de ağı yerel çözümlerde dolaşmasına neden olur. Momentum katsayısı 0.6da sabit tutularak 0.1-0.9 arasındaki öğrenme katsayılarında TANSIG ve LOGSIG aktivasyon fonksiyonları kullanılarak denemeler yapılmıştır.

Çizelge 6.2 : Öğrenme katsayısı belirlenmesi girdiler.

Gizli Katman Sayısı	1
Nöron Sayısı	10
Eğitim Fonksiyonu	TRAININGDM
Öğrenme Fonksiyonu	LEARNINGDM
Transfer Fonksiyonu	TANSIG-LOGSIG
Çevrim Sayısı	1000
Momentum Katsayısı	0.6

Çizelge 6.3 : Öğrenme katsayısı belirlenmesi sonuçlar.

Öğrenme Katsayısı	Momentum Katsayısı	TANSIG		LOGSIG	
		MAPE	MSE	MAPE	MSE
0.1	0.6	20,31	25.735.636	32,05	63.972.341
0.2	0.6	8,01	8.351.337	22,63	35.092.805
0.3	0.6	30,33	67.671.187	8,48	6.407.941
0.4	0.6	6,49	4.271.235	22,91	35.782.138
0.5	0.6	11,88	9.687.071	19,97	29.381.445
0.6	0.6	18,95	22.901.858	16,88	21.064.350
0.7	0.6	12,17	11.667.990	22,00	33.007.050
0.8	0.6	38,21	85.969.723	17,16	20.169.962
0.9	0.6	18,81	23.041.814	31,88	60.311.014

Minimum MSE ve MAPE değerleri TANSIG transfer fonksiyonu ile 0.2 ve 0.4 öğrenme katsayılarında elde edilmiştir.

6.3.2 Momentum katsayısının belirlenmesi

Momentum katsayısı bir önceki iterasyondaki değişimin bir oranının yeni iterasyona eklenmesidir. Küçük olması yerel çözümlerden kurtulmayı zorlaştırır, büyük olması ise tek çözüme ulaşmada sorun yaratabilir. Optimumun 0.6 ve 0.8 arasında olduğu düşünülmektedir.

Bir önceki adımdaki 0.2 ve 0.4 öğrenme katsayıları ile 0.1-0.9 arasındaki momentum katsayıları kullanılarak denemeler yapılmıştır.

Çizelge 6.4 : Momentum katsayısı belirlenmesi girdiler.

Gizli Katman Sayısı	1
Nöron Sayısı	10
Eğitim Fonksiyonu	TRAININGDM
Öğrenme Fonksiyonu	LEARNINGDM
Transfer Fonksiyonu	TANSIG
İterasyon Sayısı	1000
Öğrenme Katsayısı	0.2-0.4

Çizelge 6.5 : Momentum katsayısı belirlenmesi sonuçlar.

Öğrenme Katsayısı	Momentum Katsayısı	MAPE	MSE	Öğrenme Katsayısı	Momentum Katsayısı	MAPE	MSE
0.2	0.1	20,38	25.949.268	0.4	0.1	7,67	4.595.000
0.2	0.2	7,90	8.246.339	0.4	0.2	22,63	35.092.805
0.2	0.3	30,33	67.671.187	0.4	0.3	9,18	8.191.195
0.2	0.4	6,51	4.286.530	0.4	0.4	18,45	22.098.646
0.2	0.5	11,52	9.207.877	0.4	0.5	16,68	19.659.037
0.2	0.6	4,12	2.072.798	0.4	0.6	22,06	43.311.805
0.2	0.7	15,92	18.726.891	0.4	0.7	16,59	18.975.315
0.2	0.8	31,77	64.491.307	0.4	0.8	17,68	21.461.368
0.2	0.9	18,65	23.680.820	0.4	0.9	29,15	52.258.124

Öğrenme katsayısının 0.2 ve momentum katsayısının 0.6 olduğu durumda en düşük MAPE ve MSE değerleri elde edilmiştir.

6.3.3 İterasyon sayısının belirlenmesi

Ağın belirli bir çevrim sayısından sonrası öğrenmesinin durduğu düşünülmektedir. Öğrenme katsayısının 0.2 ve momentum katsayısının 0.6 olduğu durum için optimum iterasyon sayısının belirlenmesi için 250-5000 arasındaki iterasyon sayıları ile denemeler yapılmıştır.

Çizelge 6.6 : İterasyon sayısının belirlenmesi girdiler.

Gizli Katman Sayısı	1
Nöron Sayısı	10
Eğitim Fonksiyonu	TRAININGDM
Öğrenme Fonksiyonu	LEARNINGDM
Transfer Fonksiyonu	TANSIG
Öğrenme Katsayısı	0.2
Momentum Katsayısı	0.6
İterasyon Sayısı	250-5000

Çizelge 6.7 : İterasyon sayısının belirlenmesi sonuçları.

Öğrenme Katsayısı	Momentum Katsayısı	İterasyon Sayısı	MAPE	MSE
0.2	0.6	250	17,5	20.202.752
0.2	0.6	500	8,3	6.617.845
0.2	0.6	750	9,6	7.116.530
0.2	0.6	1000	6,7	3.689.628
0.2	0.6	1250	19,6	27.607.164
0.2	0.6	1500	21,8	32.205.032
0.2	0.6	1750	26,9	43.626.477
0.2	0.6	2000	6,1	3.967.771
0.2	0.6	2250	4,5	1.817.006
0.2	0.6	2500	14,4	15.061.798
0.2	0.6	2750	6,2	3.063.946
0.2	0.6	3000	18,3	22.957.416
0.2	0.6	3500	6,2	6.387.456
0.2	0.6	4000	20,3	28.406.648
0.2	0.6	4500	5,9	3.904.967
0.2	0.6	5000	6,4	3.311.876

Optimum iterasyon sayısı minimum MAPE ve MSE değerlerine göre 2250 olarak belirlenmiştir.

6.3.4 Nöron sayısının belirlenmesi

Nöron sayısının olabildiğince az olması YSA'nın genelleme yeteneğini arttırmaktadır. Fazla olması ağırlık verileri ezberlemesine sebep olur. Optimum hücre sayısının belirlenmesi için 1'den 20'ye kadar hücre sayıları ile denemeler yapılmıştır.

Çizelge 6.8 : Nöron sayısının belirlenmesi girdileri.

Gizli Katman Sayısı	1
Eğitim Fonksiyonu	TRAININGDM
Öğrenme Fonksiyonu	LEARNINGDM
Transfer Fonksiyonu	TANSIG
Öğrenme Katsayısı	0.2
Momentum Katsayısı	0.6
İterasyon Sayısı	2250
Nöron Sayısı	1-20

Çizelge 6.9 : Nöron sayısının belirlenmesi sonuçlar.

Öğrenme Katsayısı	Momentum Katsayısı	İterasyon Sayısı	Hücre Sayısı	MAPE	MSE
0.2	0.6	2250	1	17,81	22.959.196
0.2	0.6	2250	2	20,65	28.950.080
0.2	0.6	2250	3	10,69	7.259.422
0.2	0.6	2250	4	25,88	47.011.835
0.2	0.6	2250	5	6,67	3.627.614
0.2	0.6	2250	6	15,76	14.048.342
0.2	0.6	2250	7	6,41	3.407.985
0.2	0.6	2250	8	14,21	14.978.954
0.2	0.6	2250	9	21,95	30.164.577
0.2	0.6	2250	10	24,52	38.190.054
0.2	0.6	2250	11	9,46	7.946.127
0.2	0.6	2250	12	21,89	33.572.832
0.2	0.6	2250	13	9,68	7.420.282
0.2	0.6	2250	14	38,64	91.672.450
0.2	0.6	2250	15	15,73	17.521.245
0.2	0.6	2250	16	21,99	33.647.130
0.2	0.6	2250	17	10,61	7.833.448
0.2	0.6	2250	18	20,84	29.431.087
0.2	0.6	2250	19	18,12	20.900.313
0.2	0.6	2250	20	9,30	7.303.879

Optimum nöron sayısı 7 olarak belirlenmiştir.

6.3.5 Katman sayısının belirlenmesi

Öğrenme katsayısı 0.2, momentum katsayısı 0.6, iterasyon sayısı 2250, nöron sayısı 7 olarak belirlendikten sonra optimum katman sayısı belirlenecektir.

Çizelge 6.10 : Katman sayısının belirlenmesi girdiler.

Eğitim Fonksiyonu	TRAININGDM
Öğrenme Fonksiyonu	LEARNINGDM
Transfer Fonksiyonu	TANSIG
Öğrenme Katsayısı	0.2
Momentum Katsayısı	0.6
İterasyon Sayısı	2250
Nöron Sayısı	7
Gizli Katman Sayısı	1-16


Çizelge 6.11 : Katman sayısının belirlenmesi çıktıları.

Öğrenme Katsayısı	Momentum Katsayısı	İterasyon Sayısı	Hücre Sayısı	Katman Sayısı	MAPE	MSE
0.2	0.6	2250	7	1	15,1	15.637.399
0.2	0.6	2250	7	2	24,7	43.478.961
0.2	0.6	2250	7	3	19,2	27.108.030
0.2	0.6	2250	7	4	23,3	35.394.970
0.2	0.6	2250	7	5	3,5	1.296.810
0.2	0.6	2250	7	6	5,9	2.932.720
0.2	0.6	2250	7	7	10,1	7.407.456
0.2	0.6	2250	7	8	9,1	6.204.584
0.2	0.6	2250	7	9	6,2	3.319.608
0.2	0.6	2250	7	10	18,7	25.582.211
0.2	0.6	2250	7	11	6,1	4.555.246
0.2	0.6	2250	7	12	15,3	13.308.799
0.2	0.6	2250	7	13	8,2	5.448.852
0.2	0.6	2250	7	14	21,7	37.371.655
0.2	0.6	2250	7	15	20,5	27.903.288
0.2	0.6	2250	7	16	9,5	6.826.289
0.2	0.6	2250	7	17	5,1	2.260.077
0.2	0.6	2250	7	18	23,6	37.746.886
0.2	0.6	2250	7	19	7,8	4.945.692
0.2	0.6	2250	7	20	17,3	18.766.561


Katman sayısı 5 olarak belirlenmiştir.

6.3.6 Yapay sinir ağının test edilmesi

Belirlenen ağ özellikleri kullanılarak MATLABda Neuralnetwork programında ağ eğitilmiştir.



Şekil 6.12 : Ağın yaratılması.



Şekil 6.13 : Ağın parametrelerinin girilmesi.

Ağın eğitiminden sonra test için ayrılan 7 aylık veri ağa verilmiştir. Gerçek satış değerleri ile ağın tahmin ettiği değerler, MAPE ve MSE değerleri aşağıdaki gibi olmuştur. Ortalama MAPE değeri 25,33 olmuştur. Çizelge 6.12de tahmin değerleri ve MAPE ve MSE değerleri verilmiştir. MAPE değerini arttıran Ağustos ayı değeridir. İlgili ayda otomotiv sektöründe fabrikalar komple tatile girerler. Bu sebeple satışlar düşer. Ortalama 2 hafta sürer bu tatil, bu sebeple ağa böyle bilgi verilmediği için tahmin hatası kaçınılmazdır. Aynı zamanda bu bilgiyi bilmesek bile mevsimsel indeks hesabı ile aylık olarak indekslere baktığımızda aylık indeksler Çizelge 6.13deki gibi çıkmıştır. Ağustos indeksine bakıldığında oranın 0,52 olduğu görülmektedir. Ağustos tahminini indeks ile düzelttiğimizde durum Çizelge 6.14 deki gibi olmaktadır. Ortalama MAPE değeri 10.3e düşmektedir.

Çizelge 6.12 : Test sonuçları.

Ay	Gerçek Değer	Tahmin Değeri	MAPE	MSE
Haziran	27978	27349	2,2	395.504
Temmuz	21692	24476	12,8	7.752.340
Ağustos	8588	18647	117,1	101.179.617
Eylül	24470	25787	5,4	1.733.679
Ekim	28832	26257	8,9	6.629.617
Kasım	28706	22752	20,7	35.453.088
Aralık	27488	24733	10,0	7.592.196

Çizelge 6.13 : Aylık indeks değerleri.

Ay	Mevsimsel İndeks
Ocak	0,92
Şubat	1,08
Mart	1,15
Nisan	1,03
Mayıs	0,88
Haziran	1,09
Temmuz	0,95
Ağustos	0,52
Eylül	1,03
Ekim	1,17
Kasım	1,16
Aralık	1,06

Çizelge 6.14 : Ağustos düzenlemesinden sonra test sonuçları.

Ay	Gerçek Değer	Tahmin Değeri	MAPE	MSE
Haziran	27978	27349	2,2	395.504
Temmuz	21692	24476	12,8	7.752.340
Ağustos	8588	9613	11,94	1.050.886
Eylül	24470	25787	5,4	1.733.679
Ekim	28832	26257	8,9	6.629.617
Kasım	28706	22752	20,7	35.453.088
Aralık	27488	24733	10,0	7.592.196

6.4 Çoklu Regresyon Yöntemi ile Tahmin Uygulaması

Yukarıda bahsedilmiş olan aynı girdi değişkenleri ile SPSS programında regresyon çalışılmıştır. Eşdoğrusallık (collinearity) ilişkileri de kontrol edilerek çıkan regresyon tabloları aşağıdaki gibi olmuştur. R değeri (tahmin edebilme derecesi) %85 çıkmıştır. Regresyon Otomobil Üretimi, Euro kuru, Taşıt Kredisi Faiz oranı ve Tüketici Güven Endeksi değişkenlerini kullanmıştır.

Model Summary

Model	R	R Square	Adjusted R Square	Std. Error of the Estimate	R Square Change	Change Statistics			Sig. F Change
						F Change	df1	df2	
1	.760 ^a	.578	.564	3322.85836	.578	41.030	1	30	.000
2	.858 ^b	.737	.719	2668.36439	.159	17.522	1	29	.000
3	.902 ^c	.814	.795	2279.83906	.078	11.726	1	28	.002
4	.932 ^d	.870	.850	1946.85619	.055	11.397	1	27	.002

a. Predictors: (Constant), Otomobil_Üretimi

b. Predictors: (Constant), Otomobil_Üretimi, Euro

c. Predictors: (Constant), Otomobil_Üretimi, Euro, Faiz

d. Predictors: (Constant), Otomobil_Üretimi, Euro, Faiz, TGE

Şekil 6.14 : Regresyon sonuçları.**Coefficients^a**

Model		Unstandardized Coefficients		Standardized Coefficients	t	Sig.	Correlations			Collinearity Statistics	
		B	Std. Error	Beta			Zero-order	Partial	Part	Tolerance	VIF
1	(Constant)	5232.021	2921.083		1.791	.083					
	Otomobil_Üretimi	.261	.041	.760	6.405	.000	.760	.760	.760	1.000	1.000
2	(Constant)	29075.538	6160.264		4.720	.000					
	Otomobil_Üretimi	.360	.040	1.047	8.919	.000	.760	.856	.850	.658	1.519
	Euro	-9939.014	2374.414	-.492	-4.186	.000	.121	-.614	-.399	.658	1.519
3	(Constant)	26304.008	5325.167		4.940	.000					
	Otomobil_Üretimi	.401	.037	1.167	10.984	.000	.760	.901	.894	.587	1.703
	Euro	-17188.088	2932.033	-.850	-5.862	.000	.121	-.742	-.477	.315	3.172
	Faiz	1573.417	459.473	.413	3.424	.002	.073	.543	.279	.456	2.193
4	(Constant)	47095.358	7655.568		6.152	.000					
	Otomobil_Üretimi	.415	.031	1.208	13.199	.000	.760	.930	.918	.577	1.734
	Euro	-19591.000	2602.998	-.969	-7.526	.000	.121	-.823	-.523	.292	3.429
	Faiz	1878.142	402.613	.493	4.665	.000	.073	.668	.324	.433	2.309
	TGE	-270.782	80.209	-.244	-3.376	.002	-.132	-.545	-.235	.922	1.084

Şekil 6.15 : Regresyon katsayıları.

VIF değerleri 10'un altında ve tolerans istatistikleri de 0.2'nin üzerinde olduğu için tahmin değişkenleri arasında mükemmel doğrusal ilişkiden söz edilemez. Kısmi korelasyonlar ise bağımsız değişkenlerle bağımlı değişken arasındaki ilişkiyi ifade eder. En yüksek ilişki Otomobil üretimi ile doğru orantılı, Euro kuruyla ters orantılı gözükmemektedir. Sig. Değerlerine baktığımızda da tüm değişkenler için 0.05'ten küçük çıktığı için bağımlı değişken üzerinde anlamlı etkileri olduğu söylenebilir.

Regresyon denklemi aşağıdaki gibi olacaktır:

$$\text{Satış} = 47095.358 + (\text{OtomobilÜretimi} \times 0.415) - (19591 \times \text{EuroKuru}) + (1878.142 \times \text{FaizOranı}) - (270.782 \times \text{TGE})$$

Değerler buna göre yerine konulduğunda fiili değerler, tahmini değerler, MAPE, MSE değerleri aşağıdaki gibi olmaktadır. Ortalama MAPE değeri 7.42 olmuştur.

Çizelge 6.15 : Regresyon tahminleri ve fiili değerler karşılaştırma.

Gerçek Değer	Regresyon Tahmin	MAPE	MSE
21504	23.427,8	8,95	3.700.997
23442	23.597,2	0,66	24.086
20860	20.251,2	2,92	370.695
12169	10.538,9	13,40	2.657.150
25215	25.044,4	0,68	29.101
24606	20.880,2	15,14	13.881.947
25434	25.935,1	1,97	251.073
24610	26.421,7	7,36	3.282.239
26418	24.689,1	6,54	2.989.123
26586	25.592,8	3,74	986.458
27736	28.510,9	2,79	600.516
22636	25.462,4	12,49	7.988.557
14080	18.254,6	29,65	17.426.964
25406	25.615,8	0,83	44.030
24392	22.937,2	5,96	2.116.337
15309	13.549,9	11,49	3.094.590
22616	21.327,7	5,70	1.659.651
29170	27.284,1	6,47	3.556.520
27472	25.237,5	8,13	4.992.889
22618	24.639,8	8,94	4.087.499
17850	17.662,1	1,05	35.323
25176	25.928,3	2,99	565.924
27552	28.839,1	4,67	1.656.578
26956	26.458,4	1,85	247.587
26376	24.434,4	7,36	3.769.844
27978	26.879,3	3,93	1.207.065
21692	22.385,6	3,20	481.104
8588	12.598,9	46,70	16.087.450
24470	22.785,2	6,89	2.838.596
28832	29.049,5	0,75	47.301
28706	28.465,5	0,84	57.826
27488	28.467,6	3,56	959.542

Regresyon datasında da son 6 ayın verilerine baktığımızda 46,7 MAPE değeri görülmektedir. Son 6 ay için MAPE değeri ortalaması 9,41dir. İlgili dönem yine Ağustos ayına denk gelmektedir. Aynı şekilde Ağustos tahmininin yarısını alarak düzenleme yaptığımızda ortalama MAPE değeri 6,22ye düşmektedir.

Çizelge 6.16 : Ağustos düzenlemesinden sonra regresyon sonuçları.

Ay	Fiili Değer	Regresyon Tahmini	MAPE	MSE
Haziran	27978	26879	3,9	1.207.065
Temmuz	21692	22386	3,2	481.104
Ağustos	8588	6495	24,37	4.379.758
Eylül	24470	22785	6,9	2.838.596
Ekim	28832	29049	0,8	47.301
Kasım	28706	28466	0,8	57.826
Aralık	27488	28468	3,6	959.542

6.5 Regresyonda Kullanılan Girdi Değişkenleri ile YSA

Bu aşamada regresyon çalışmasında dikkate alınan girdi değişkenleri Otomobil Üretimi, Euro kuru, Taşıt Kredisi Faiz oranı ve Tüketici Güven Endeksi ile YSA çalışması yapılacaktır. Tüm girdi değişkenleri ile yapılan YSA çalışmasındaki adımların aynıları tekrarlanacaktır. Eğitim, aktivasyon, öğrenme fonksiyonları da aynı kullanılacaktır.

6.5.1 Öğrenme katsayısının belirlenmesi

Başlangıç olarak 0.6 momentum katsayısı sabit tutularak 0.1-0.9 arasındaki öğrenme katsayıları ile denemeler yapıldı. Minimum MAPE ve MSE değerlerini veren 0.3 ve 0.8 öğrenme katsayıları seçilmiştir.

Çizelge 6.17 : Öğrenme katsayısının belirlenmesi girdiler.

Eğitim Fonksiyonu	TRAININGDM
Öğrenme Fonksiyonu	LEARNINGDM
Transfer Fonksiyonu	TANSIG
İterasyon Sayısı	1000
Gizli Katman Sayısı	1
Nöron Sayısı	10
Momentum Katsayısı	0.6
Öğrenme Katsayısı	0.1-0.9

Çizelge 6.18 : Öğrenme katsayısının belirlenmesi çıktılar.

Öğrenme Katsayısı	Momentum Katsayısı	MAPE	MSE
0,1	0,6	12,2	12.171.502
0,2	0,6	19,3	34.375.052
0,3	0,6	5,5	3.123.057
0,4	0,6	18,9	23.870.837
0,5	0,6	10,9	8.878.473
0,6	0,6	11,1	9.577.654
0,7	0,6	13,3	13.024.074
0,8	0,6	4,3	1.680.082
0,9	0,6	21,9	31.103.795

6.5.2 Momentum katsayısının belirlenmesi

Momentum katsayısının belirlenmesi için 0,3 ve 0,8 öğrenme katsayıları ile 0.1-0.9 arasındaki momentum katsayıları ile denemeler yapılmıştır.

Çizelge 6.19 : Momentum katsayısının belirlenmesi girdiler.

Eğitim Fonksiyonu	TRAINGDM
Öğrenme Fonksiyonu	LEARNINGDM
Transfer Fonksiyonu	TANSIG
İterasyon Sayısı	1000
Gizli Katman Sayısı	1
Nöron Sayısı	10
Öğrenme Katsayısı	0.3-0.8
Momentum Katsayısı	0.1-0.9

Çizelge 6.20 : Momentum katsayısının belirlenmesi çıktılar.

Öğrenme Katsayısı	Momentum Katsayısı	MAPE	MSE
0.3	0.1	9,22	9.199.242
0.3	0.2	6,72	4.360.068
0.3	0.3	9,07	6.468.093
0.3	0.4	14,41	15.657.225
0.3	0.5	19,75	27.221.822
0.3	0.6	10,85	9.206.942
0.3	0.7	21,05	26.282.198
0.3	0.8	9,82	7.057.030
0.3	0.9	9,58	7.293.563
0.8	0.1	12,30	9.293.234
0.8	0.2	17,99	24.275.989
0.8	0.3	6,03	3.016.013

Çizelge 6.21 : Momentum katsayısının belirlenmesi çıktıları (Devam).

Öğrenme Katsayısı	Momentum Katsayısı	MAPE	MSE
0.8	0.4	26,53	47.427.708
0.8	0.5	7,53	4.592.756
0.8	0.6	17,87	22.434.162
0.8	0.7	17,78	21.348.564
0.8	0.8	14,24	15.036.993
0.8	0.9	17,83	20.830.922

6.5.3 İterasyon sayısının belirlenmesi

Öğrenme katsayısı 0.8 ve momentum katsayısı da 0.3 olarak belirlendikten sonra, optimum çevrim sayısının belirlenmesi için 250-5000 arasındaki değerlerle denemeler yapılmıştır.

En uygun çevrim sayısı 4000 olarak tespit edilmiştir.

Çizelge 6.22 : Çevrim sayısının belirlenmesi girdileri.

Eğitim Fonksiyonu	TRAININGDM
Öğrenme Fonksiyonu	LEARNINGDM
Transfer Fonksiyonu	TANSIG
Gizli Katman Sayısı	1
Nöron Sayısı	10
Öğrenme Katsayısı	0.8
Momentum Katsayısı	0.3
İterasyon Sayısı	250-5000

Çizelge 6.23 : İterasyon sayısının belirlenmesi çıktıları.

Çevrim Sayısı	Öğrenme Katsayısı	Momentum Katsayısı	MAPE	MSE
250	0.8	0.3	6,2	4.190.666
500	0.8	0.3	9,6	6.287.237
750	0.8	0.3	5,9	3.610.396
1000	0.8	0.3	14,0	15.129.516
1250	0.8	0.3	12,2	8.579.842
1500	0.8	0.3	15,6	17.394.432
1750	0.8	0.3	13,6	13.622.894
2000	0.8	0.3	7,3	4.323.962
2250	0.8	0.3	33,8	70.171.933
2500	0.8	0.3	11,2	8.518.356

Çizelge 6.24 : İterasyon sayısının belirlenmesi çıktıları (Devam).

Çevrim Sayısı	Öğrenme Katsayısı	Momentum Katsayısı	MAPE	MSE
2750	0.8	0.3	15,2	16.296.420
3000	0.8	0.3	6,9	3.594.454
3500	0.8	0.3	11,6	11.887.395
4000	0.8	0.3	5,4	2.308.654
4500	0.8	0.3	21,2	30.140.636
5000	0.8	0.3	7,2	4.845.944

6.5.4 Nöron sayısının belirlenmesi

Öğrenme katsayısı, momentum katsayısı ve çevrim katsayısı belirlendikten sonra uygun nöron sayısının belirlenmesi için 1-20 arası nöron sayıları ile denemeler yapılmıştır.

En uygun nöron sayısı 9 olarak belirlenmiştir.

Çizelge 6.25 : Nöron sayısı belirlenmesi girdileri.

Eğitim Fonksiyonu	TRAINGDM
Öğrenme Fonksiyonu	LEARNINGDM
Transfer Fonksiyonu	TANSIG
Gizli Katman Sayısı	1
Öğrenme Katsayısı	0.8
Momentum Katsayısı	0.3
İterasyon Sayısı	4000
Nöron Sayısı	1-20

Çizelge 6.26 : Nöron sayısı belirlenmesi çıktıları.

Nöron Sayısı	Çevrim Sayısı	Öğrenme Katsayısı	Momentum Katsayısı	MAPE	MSE
1	4000	0.8	0.3	17,20	17.842.445
2	4000	0.8	0.3	17,00	19.427.804
3	4000	0.8	0.3	18,29	20.623.885
4	4000	0.8	0.3	14,61	13.554.299
5	4000	0.8	0.3	20,25	27.032.600
6	4000	0.8	0.3	13,10	11.266.595
7	4000	0.8	0.3	11,02	9.665.634
8	4000	0.8	0.3	11,18	10.372.864
9	4000	0.8	0.3	9,75	7.019.708
10	4000	0.8	0.3	14,09	17.484.105
11	4000	0.8	0.3	11,67	11.133.992
12	4000	0.8	0.3	10,36	7.688.437
13	4000	0.8	0.3	10,22	8.260.699
14	4000	0.8	0.3	11,33	12.594.908
15	4000	0.8	0.3	26,10	58.513.688
16	4000	0.8	0.3	12,33	11.508.894
17	4000	0.8	0.3	10,17	7.715.206
18	4000	0.8	0.3	21,44	32.740.993
19	4000	0.8	0.3	14,93	15.173.333
20	4000	0.8	0.3	10,52	11.822.971

6.5.5 Katman sayısının belirlenmesi

Öğrenmesi ve momentum katsayıları, çevrim sayısı, nöron sayısı belirlendikten sonra son aşama olarak katman sayısı belirlenecektir. Bunun için 1-8 arasındaki katman sayıları ile denemeler yapılmıştır. Uygun katman sayısı 3 olarak belirlenmiştir.

Çizelge 6.27 : Katman sayısının belirlenmesi girdileri.

Eğitim Fonksiyonu	TRAININGDM
Öğrenme Fonksiyonu	LEARNINGDM
Transfer Fonksiyonu	TANSIG
Öğrenme Katsayısı	0.8
Momentum Katsayısı	0.3
İterasyon Sayısı	4000
Nöron Sayısı	9
Gizli Katman Sayısı	1-8

Çizelge 6.28 : Katman sayısının belirlenmesi çıktıları.

Gizli Katman Sayısı	Nöron Sayısı	Çevrim Sayısı	Öğrenme Katsayısı	Momentum Katsayısı	MAPE	MSE
1	9	4000	0.8	0.3	7,31	4.247.834
2	9	4000	0.8	0.3	11,33	8.543.345
3	9	4000	0.8	0.3	6,92	3.654.275
4	9	4000	0.8	0.3	12,05	11.051.036
5	9	4000	0.8	0.3	8,47	5.001.193
6	9	4000	0.8	0.3	17,79	24.334.409
7	9	4000	0.8	0.3	7,27	4.685.082
8	9	4000	0.8	0.3	27,74	61.586.696

6.5.6 Yapay Sinir Ağının testi

Belirlenen ağ değerlerine göre ağ yaratılmış, eğitilmiş ve test için 7 aylık data ağa sunulmuştur. Gerçek ve tahmin değerleri, MAPE ve MSE değerleri aşağıdaki gibi gerçekleşmiştir. Ortalama MAPE değeri 9,35 olarak gerçekleşmiştir. Yine MAPE değeri 52,5 olan ay Ağustos ayıdır. Burda da yukarıdaki düzeltme yapıldığında MAPE değeri 4.91e düşmektedir.

Çizelge 6.29 : Regresyon girdileriyle YSA test sonuçları.

Ay	Gerçek Değer	Tahmin	MAPE	MSE
Haziran	27978	27924	0,2	2.924
Temmuz	21692	22725	4,8	1.067.294
Ağustos	8588	13093	52,5	20.296.762
Eylül	24470	24014	1,9	208.182
Ekim	28832	28298	1,9	285.573
Kasım	28706	29008	1,1	91.377
Aralık	27488	28383	3,3	801.257

Çizelge 6.30 : Ağustos düzenlenmesinden sonra 2. Adım YSA sonuçları.

Ay	Gerçek Değer	Tahmin	MAPE	MSE
Haziran	27978	27924	0,2	2.924
Temmuz	21692	22725	4,8	1.067.294
Ağustos	8588	6750	21,4	3.378.130
Eylül	24470	24014	1,9	208.182
Ekim	28832	28298	1,9	285.573
Kasım	28706	29008	1,1	91.377
Aralık	27488	28383	3,3	801.257



7. SONUÇ VE ÖNERİLER

Tahmin geçmiş değerler kullanılarak geleceğe yönelik kestirimler yapmaktır. Yönetimsel faaliyetlerin verimli olabilmesi için geleceğin tahmin edilmesi ve ona göre aksiyonlar alınması önemlidir. Uygulamasını yaptığımız işletme problemi için ürün grubu bazında geleceğe yönelik tahmin yapabilmek için Yapay Sinir Ağları yöntemi ve Regresyon yöntemi kullanılmıştır. Regresyon bağımlı ve bağımsız değişkenler arasında doğrusal bir ilişki olduğunu varsaymaktadır. YSA ile ise doğrusal ve doğrusal olmayan tüm ilişkiler dikkate alınmaktadır.

İşletmede tahmini yapılacak ürün grubunun seçimi için satış-pazarlama çalışanlarının öngörülleri ile oluşturulan tahmin sonuçlarının fiili değerlerle karşılaştırılması sonucu en fazla sapma gözlenen ürün grubu seçilmiştir. Otomotiv sektöründe talep tahmin çalışmalarında kullanılan girdi değişkenlerinden faydalanılarak 10 adet girdi değişkeni belirlenmiştir. 32 aylık geçmiş satış datasına ulaşılabildiği için 32 aylık geçmiş datalar kullanılmıştır. Bağımlı değişken olarak Türkiye'deki ilgili markanın otomobil üretimi sayıları, satış rakamları, Euro ve dolar kurları, benzin fiyatları, Gayrisafi Yurtiçi Hasıla, Tüketici Güven Endeksi, Reel Kesim Güven Endeksi, taşıt kredisi faiz oranları ve TUIK tarafından hazırlanan gelecek 12 ayda otomobil satınalma ihtimali anketi değişkenleri kullanılmıştır. Bağımsız değişken olarak da ilgili ürün grubu için aylık satış rakamları kullanılmıştır.

Regresyon ve YSA sonuçlarına bakıldığında tahmin hatalarında Ağustos ayı düzeltmesiz regresyon 9,4 MAPE değeri verirken, YSA 25,33 MAPE değeri vermiştir. Düzeltmeden sonra regresyon MAPE değeri 6,22 olurken YSA MAPE değeri 10,3 olmuştur. Regresyonun daha iyi sonuç verdiği görülmüştür. Sonuçları iyileştirmek için birden fazla yöntemin birlikte kullanılması çalışmalarda denenmektedir ve başarılı sonuçlar alınmaktadır. [67] Burada da regresyondan yararlanılarak tekrar bir YSA çalışması yapılmıştır. Bu durumda MAPE değeri düzeltmesiz 9,35 olmuştur. Düzeltmeden sonra 4,91 düşmüştür. Sonuçların iki yöntemin ayrı ayrı kullanılmasından daha başarılı olduğu gözlenmiştir.

Çalışma iş dünyasında talep öngörülerinden yararlanarak planlamalar yapan, bu planlar üzerine kararlar alan çalışanlar ve yöneticiler için fayda sağlayacaktır. Otomotiv sektöründe talep tahmin çalışmalarına YSA ve regresyon birlikte kullanımı ile katkı sağlanmıştır.

Gelecek çalışmalarda daha fazla geçmiş data bilgisi olan farklı bir gruba ile denemeler yapılabilir. Otomobil satışına etki edebilecek farklı değişkenler modele dahil edilebilir. Ürün grubu bazından ürün bazında tahmine geçiş yapılabilir. Bu noktada işin içine müşteri tercihleri de gireceğinden nicel yöntemlerden de faydalanılabilir. Farklı eğitim ve aktivasyon fonksiyonları ile denemeler yapıp, sonuçlar karşılaştırılabilir.



KAYNAKLAR

- [1] **Görener, A., ve Görener, Ö.** (2008) Türk Otomotiv Sektörünün Ülke Ekonomisine Katkileri Ve Geleceğe Yönelik Sektörel Beklentiler, *Journal of Yasar University*, 3(10),1213-1232
- [2] **Akgül, B.** (2010) Türkiye'deki Otomotiv Sektörü Ve Örnek Bir Talep Tahmin Çalışması, *Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul*
- [3] **Keah Choon, T., Kannan, V., ve Hanfield, Robert B (1998)** Supply Chain Management: Supplier Performance And Firm Performance, *International Journal of Purchasing and Materials Management*;2-9
- [4] **Chuang, M. ve Shaw W.** (2000) Distinguishing The Critical Success Factors Between E-Commerce, Enterprise Resource Planning And Supply Chain Management *Proceeding of International Engineering Management Conference, New Mexico* 150
- [5] **Fredendall, Lawrence D. ve Hill, E.** (2001) Basics of Supply Chain Management *CRC Press LLC*
- [6] *Vikipedi Erişim: 10 Ocak, 2017*, <https://tr.wikipedia.org/wiki/Otomotiv>
- [7] *Vikipedi Erişim: 13 Ocak, 2017*, https://en.wikipedia.org/wiki/Automotive_industry
- [8] **Reid, D. ve Sanders, N.** (2012) Operations Management An Integrated Approach, *John Wiley& Sons*
- [9] *Vikipedi Erişim: 18 Ocak, 2017*, https://tr.wikipedia.org/wiki/T%C3%BCrk_otomotiv_sanayisi
- [10] **Öztayşi, B. ve Boltürk E.** (2014) Fuzzy Methods for Demand Forecasting in Supply Chain Management, *Studies in Fuzziness and Soft Computing*,313, 243-268
- [11] **Özdemir, A. ve Özdemir A.** (2006) Talep Tahminlemede Kullanılan Yöntemlerin Karşılaştırılması:Seramik Ürün Grubu Firma Uygulaması, *Ege Akademik Bakış* 2(6), 105-114
- [12] **Gor, R. M.** (2009) Forecasting Techniques, *Industrial Statistics and Operational Management*, Retrieved Ocak 30,2017 from: <http://nsdl.niscair.res.in/jspui/bitstream/123456789/829/1/CHAPTER-6%20FORECASTING%20TECHNIQUES-%20Formatted.pdf>

- [13] **Karaatlı, M., Ömürbek, N., Helvacıoğlu, Ö., Tokgöz, G.** (2012) Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini, *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100
- [14] **Ryu, K.** (2002) The Livaluation of Forecasting Methods At An Institutional Foodservice Dining Facility, *Yüksek Lisans Tezi, Texas Tech Üniversitesi, Amerika*, Retrieved from: <https://www.researchgate.net>
- [15] **Kaynar, O., Taştan, S.** (2009) Zaman Serisi Analizinde Mlp Yapay Sinir Ağları ve Arima Modelinin Karşılaştırılması, *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 33, 161-172
- [16] **Emel, G.ve Taşkın, Ç.** (2002) Genetik Algoritmalar ve Uygulama Alanları, *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21(1), 129-152
- [17] **Çuhadar, M.** (2014) Muğla İline Yönelik Dış Turizm Talebinin Modellenmesi ve 2012 – 2013 Yillari İçin Tahminlenmesi, *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 12
- [18] **Ataseven, B.** (2013) Yapay Sinir Ağları ile Öngörü Modellemesi, *Öneri Dergisi, Marmara Üniversitesi*, 10(39),101-115
- [19] **Serper, Ö.** (2010) Uygulamalı İstatistik, *Ezgi Kitabevi, Bursa*
- [20] **Yiğit, V.** (2011) Genetik Algoritma ile Türkiye Net Elektrik Enerjisi Tüketiminin 2020 Yılına Kadar Tahmini, *International Journal of Engineering Research and Development*, 3(2),37-41
- [21] **Zhu, Q., Crotty, J., Sarkis, J.** (2008) A Cross-Country Empirical Comparison Of Environmental Supply Chain Management Practices In The Automotive Industry, *Asian Business & Management*,7, 467-488
- [22] **Ceylan, H. ve Haldenbilen, S.** (2005) Şehirler Arası Ulaşım Talebinin Genetik Algoritma ile Modellenmesi, *İMO Teknik Dergi*, 3599-3618
- [23] **Es, H., Kalender, Y., Hamzaçebi, C.** (2014) Yapay Sinir Ağları İle Türkiye Net Enerji Talep Tahmini, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 29(3), 495-504
- [24] **Hamzaçebi, C. ve Kutay, F.** (2004) Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini, *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19(3),227-233
- [25] **Çuhadar, M. ve Güngör, İ.** (2005) Antalya İline Yönelik Alman Turist Talebinin Yapay Sinir Ağları Yöntemiyle Tahmini, *Ticaret ve Turizm Eğitim Fakültesi Dergisi*,1,84-98
- [26] **Çuhadar, M., Kayacan, C.** (2005) Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki

- [27] **Wu, A., Hsieh, W., Tang, B.** (2006) Neural Network Forecasts Of The Tropical Pacific Sea Surface Temperatures, *Neural Networks*, 19, 145-154
- [28] **Fabbian, D., Rear, R., Lellyett, S.** (2007) Application of Artificial Neural Network Forecasts to Predict Fog at Canberra International Airport, *American Meteorological Society Weather And Forecasting*, 22, 372-381
- [29] **Önder, E., ,Hasgöl, Ö.** (2009) Yabancı Ziyaretçi Sayısının Tahmininde Boxjenkins Modeli, Winters Yöntemi Ve Yapay Sinir Ağlarıyla Zaman Serisi Analizi, *İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü Dergisi*, 20, 62-83
- [30] **Chen, G. ve Lie, T.** (2010) The Impact of Climate Change on New Zealand's Electricity Demand, *Probabilistic Methods Applied to Power Systems (PMAAPS)*, 2010 IEEE 11th International Conference
- [31] **Kaynar, O.,Taştan, S.,Demirkoparan, F.** (2010) Ham Petrol Fiyatlarının Yapay Sinir Ağları ile Tahmini, *Ege Akademik Bakış*, 10(2), 559-573
- [32] **Özkan, F.** (2012) Döviz Kuru Tahmininde Parasal Model ve Yapay Sinir Ağları Karşılaştırılması, *Business and Economics Research Journal*, 3(1), 27-39
- [33] **Hernandez, L. ve diğerleri** (2013) Experimental Analysis of the Input Variables' Relevance to Forecast Next Day's Aggregated Electric Demand Using Neural Networks, *Energies*, 6, 2927-2948
- [34] **Claveria, O.,Monte, E.,Torra, S.** (2014) Tourism Demand Forecasting With Different Neural Networks Models, *International Journal of Tourism Research*, 17, 492-500
- [35] **Akdağ, R.** (2016) Yapay Sinir Ağları, Destek Vektör Makineleri ve Box-Jenkins Yöntemleriyle Kentsel İçmesuyu Talebi Tahmini ve Karşılaştırmalı Analizi, *Business and Economics Research Journal*, 7(1), 123-138
- [36] **Aliahmadi, A., Jafari-eskandari, M., Mozafari, A., Nozari, H.** (2016) Comparing Linear Regression And Artificial Neural Networks To Forecast Total Productivity Growth In Iran, *International Journal of Information, Business and Management*, 8(1), 93-113
- [37] **Ertuğrul, İ., Bekin, A.** (2016) Türkiye'de Bazı Temel Gıda Fiyatları için Yapay Sinir Ağları ve Zaman Serisi Tahmin Modellerinin

- [38] **Mladenovic, S., Milovancevic, M., Mladenovic, I., Alizamir, M.** (2016) Economic growth forecasting by artificial neural network with extreme learning machine based on trade, import and export parameters, *Computers in Human Behaviour*, 65, 43-45
- [39] **Alper, E.** (2000) Türkiye’de Otomobil Talebinin Tahmini, *Ekonomi Bölümü, ve Ekonomi ve Ekonometri Merkezi, Boğaziçi Üniversitesi, İstanbul*
- [40] **Asilkan, Ö., Irmak, S.** (2009) İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi, *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(2), 375-391
- [41] **Gaojun, L., Boxue, L.** (2009) The Research On Combination Forecasting Model Of The Automobile Sales Forecasting System, *International Forum on Computer Science-Technology and Applications*, 82-85
- [42] **İşeri, A., Karlık, B.** (2009) An artificial neural networks approach on automobile pricing, *Expert Systems with Applications*, 36, 2155-2160
- [43] **Yazıcıoğlu, N.** (2010) *Yapay Zeka İle Talep Tahmini*, Yüksek Lisans Tezi, Uludağ Üniversitesi, Bursa
- [44] **Wang, F., Chang, K., Tzeng, C.** (2011) Using Adaptive Network-Based Fuzzy Inference System To Forecast Automobile Sales, *Expert Systems with Applications*, 38, 10587-10593
- [45] **Sa-ngasoongsong, A., Bukkapatnam, S., Kim, J., Suresh, R.** (2012) Multi-step sales forecasting in automotive industry based on structural relationship identification, *International Journal of Production Economics*, 140, 875-887
- [46] **Kitapçı, O., Özekicioğlu, H., Kaynar, O. Ve Taştan, S.** (2014) The effects of economic policies applied in Turkey to the sale of automobiles: multiple regression and neural network analysis, *Procedia Social and Behavioral Sciences*, 148, 653-661
- [47] **Akyurt, İ.** (2015) Talep Tahmininin Yapay Sinir Ağlarıyla Modellenmesi: Yerli Otomobil Örneği, *İstanbul Üniversitesi İktisat Fakültesi Ekonometri Ve İstatistik Dergisi*, 23, 147-157
- [48] **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

- [49] **Karaca, K.** (2015) *Araç Talep Tahmininde Kullanılan Yöntemlerin Karşılaştırılması*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul
- [50] **Matsumoto, M., Ikeda, A.** (2015) Examination of Demand Forecasting By Time Series Analysis for Auto Parts Remanufacturing, *Journal of Remanufacturing*, 5:1
- [51] **Rodrigues, L., Oliveira, I., Alexandre, M., Castorani, R., Jacubavicius, C.** (2015) Stocks Management Through Application Of Demand Forecast Methods: A Case Study, *Independent Journal Of Management & Production*, 7(5), 699-713
- [52] **Lolli, F., Gamberini, R., Regattieri, A., Balugani, E., Gatos, T., Gucci, S.** (2017) Single Hidden Layer Neural Networks for Forecasting Intermittent Demand, *Int. J. Production Economics*, 183, 116-128
- [53] **Ballı, M.** (2014) *Yapay Sinir Ağları İle Talep Tahmini Ve Gıda Sektöründe Uygulanması*, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul
- [54] **Sarı, M.** (2016) *Yapay Sinir Ağları Ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması*, Yüksek Lisans Tezi, Sakarya Üniversitesi, Sakarya
- [55] **Kölmek, M.A.** (2012) *Türkiye Elektrik Dengeleme ve Uzlaştırma Piyasasındaki Sistem Gün Öncesi Fiyatının Yapay Sinir Ağları Kullanarak Modellenmesi*, Yüksek Lisans Tezi Ankara Üniversitesi, Ankara
- [56] **Öztemel, E.** (2012) *Yapay Sinir Ağları, 3. Baskı, Papatya Yayıncılık, İstanbul*
- [57] **Yurtoğlu, H.** (2005) Yapay Sinir Ağları ile Öngörü Modellemesi : Bazı Makroekonomik Değişkenler İçin Türkiye Örneği, *DPT Yayınları*, (DPT-2683), 8, Ankara
- [58] **Yüksek, A.** (2007) *Hava Kirliliği Tahmininde Çoklu Regresyon Analizi Ve Yapay Sinir Ağları Yönteminin Karşılaştırılması*, Doktora Tezi, Cumhuriyet Üniversitesi, Sivas
- [59] **Adıyaman, F.** (2007) *Talep Tahmininde Yapay Sinir Ağlarının Kullanılması*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul
- [60] **Toktaş, İ. ve Aktürk, N.** (2004) Makine Tasarım İşleminde Kullanılan Yapay Zeka Teknikleri ve Uygulama Alanları, *Makine Teknolojileri Elektronik Dergisi*, 2: 7-20
- [61] **Karahan, M.** (2011) *İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması*, Doktora Tezi, Selçuk Üniversitesi, Konya

- [62] **Elmas Ç.** (2003) *Yapay Sinir Ağları (Kuram, Mimari, Eğitim, Uygulama)*, Seçkin Yayıncılık, Ankara
- [63] **Yücesoy, M.** (2011) *Temizlik Kağıtları Sektöründe Yapay Sinir Ağları İle Talep Tahmini*, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi, İstanbul
- [64] **Saygılı, Y. S.** (2008) *İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülenmesi*, Yüksek Lisans Tezi, Kara Harp Okulu Savunma Bilimleri Enstitüsü, Ankara
- [65] **Olgun, S.** (2009) *Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemleri Ve Yapay Zeka Tabanlı Bir Talep Tahmini Modelinin Uygulanması*, Yüksek Lisans Tezi, İstanbul Üniversitesi, İstanbul
- [66] **Serttaş, Z.** (2011) *Türkiye’de Perakende Sektöründe Talebi Etkileyen Etmenler Ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması*, Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi, İstanbul
- [67] **Wang, K., Deng, C., Li, J., Zhang, Y.,** (2017) Hybrid methodology for tuberculosis incidence time-series forecasting based on ARIMA and NAR neural network, *Epidemiol Infect*, Cambridge University Press, 145, 1118-1129

EKLER

EK A: Veri Seti

Yıl	Ay	Taşıt Kredisi Faizi	Otomobil Üretimi	Otomobil Satışı	Tüketici Güven Endeksi	Reel Kesim Güven Endeksi	Gelecek 12ayda otomobil satınalma ihtimali	GSYİH	Benzin Fiyatı	Dolar Kuru	Euro Kuru	Mamul Satış
2014	5	14,29	63658	4492	76	108,2	15,6	150423	4,97	2,09	2,88	21504
2014	6	13,31	67013	5025	73,7	107,5	11,9	150423	5,05	2,12	2,88	23442
2014	7	12,79	61151	4695	73,9	106,7	13,1	162384	5,08	2,12	2,87	20860
2014	8	12,84	37330	3546	73,2	106,2	12	182875	4,98	2,16	2,88	12169
2014	9	12,72	72120	5786	74	108,1	12,7	182875	4,93	2,20	2,85	25215
2014	10	12,37	62001	6177	70,3	110,1	12,9	185807	4,82	2,26	2,87	24606
2014	11	12,38	69466	6481	68,7	107,7	11,9	185807	4,62	2,23	2,79	25434
2014	12	12,60	70480	14348	67,7	108	10,4	185807	4,35	2,29	2,82	24610
2015	1	12,91	60414	2661	67,7	106,1	11,7	165747	4,16	2,33	2,72	26418
2015	2	13,06	65238	3872	68,1	104	12,2	165747	4,33	2,45	2,79	26586
2015	3	12,58	72781	5844	64,4	101,1	10,9	165747	4,43	2,58	2,81	27736
2015	4	12,79	67277	7705	65,4	102,6	11,8	187515	4,51	2,65	2,85	22636
2015	5	13,14	52339	2559	64,3	103,9	11,5	187515	4,69	2,64	2,95	14080
2015	6	13,44	73928	5626	66,4	101,7	10,8	187515	4,83	2,70	3,03	25406
2015	7	13,60	62465	6781	64,7	103,1	12,2	210667	4,71	2,69	2,97	24392
2015	8	14,14	45210	5648	62,4	103,1	13	210667	4,52	2,84	3,16	15309
2015	9	15,20	66572	5643	58,5	99,7	10,8	210667	4,52	3,00	3,37	22616

EK A (Devam)

Yıl	Ay	Taşıt Kredisı Faızı	Otomobil Üretımı	Otomobil Satışı	Tüketici Güven Endeksi	Reel Kesim Güven Endeksi	Gelecek 12ayda otomobil satınalma ihtimali	GSYİH	Benzin Fiyatı	Dolar Kuru	Euro Kuru	Mamul Satış
2015	10	15,82	77243	4503	62,8	103,6	9,9	215248	4,44	2,93	3,30	29170
2015	11	15,62	72872	6280	77,1	110,2	12,4	215248	4,35	2,87	3,09	27472
2015	12	15,18	74688	11941	73,6	108,8	12,3	215248	4,32	2,92	3,17	22618
2016	1	15,82	58205	2810	71,6	105,9	12,1	187062	4,26	3,00	3,26	17850
2016	2	16,32	72740	3553	66,6	105,2	11,4	187062	4,12	2,94	3,26	25176
2016	3	16,33	77051	6280	67	104,1	12,3	187062	4,27	2,89	3,20	27552
2016	4	15,92	74625	7297	68,5	105,7	12,6	210971	4,37	2,83	3,21	26956
2016	5	15,54	76569	7292	68,8	105,7	11,8	210971	4,53	2,93	3,32	26376
2016	6	15,30	82175	6912	69,4	104,3	12,9	210971	4,50	2,92	3,28	27978
2016	7	15,31	69030	2006	67	106,3	12,1	220675	4,37	2,95	3,26	21692
2016	8	15,45	52296	2516	74,4	103	13,8	220675	4,37	2,96	3,32	8588
2016	9	15,01	78439	2806	74,3	107,1	13	220675	4,67	2,95	3,31	24470
2016	10	14,74	98008	4325	74	103,8	12,2	244798	4,83	3,07	3,39	28832
2016	11	13,71	104737	6905	68,9	107,6	10,8	244798	4,83	3,26	3,53	28706
2016	12	13,93	106963	11492	63,4	103,6	9,8	244798	5,11	3,48	3,68	27488

ÖZGEÇMİŞ

Ad-Soyad : Nihal Kuru
Doğum Tarihi ve Yeri : 1987 - İstanbul
E-posta : nihal_kuru1987s@hotmail.com

ÖĞRENİM DURUMU:

- **Lisans** : 2010, Uludağ Üniversitesi, Mühendislik Mimarlık Fakültesi, Endüstri Mühendisliği Bölümü
- **Yükseklisans** : 2017, İstanbul Teknik Üniversitesi, İşletme Mühendisliği Anabilim Dalı, İşletme Mühendisliği Programı