

**T.C.
MANİSA CELAL BAYAR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ**

**DOKTORA TEZİ
İŞLETME ANABİLİM DALI
İŞLETME DOKTORA PROGRAMI**

**“R” PROGRAMLAMA DİLİNDE TAHMİN EDİCİ VERİ
MADENCİLİĞİ ALGORİTMALARININ MODELLENMESİ VE
PERFORMANSLARININ KARŞILAŞTIRILMASI**

Şengül CAN

**Danışman
Doç. Dr. Mustafa GERŞİL**

MANİSA–2022

**T.C.
MANİSA CELAL BAYAR ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ**

**DOKTORA TEZİ
İŞLETME ANABİLİM DALI
İŞLETME DOKTORA PROGRAMI**

**“R” PROGRAMLAMA DİLİNDE TAHMİN EDİCİ VERİ
MADENCİLİĞİ ALGORİTMALARININ MODELLENMESİ VE
PERFORMANSLARININ KARŞILAŞTIRILMASI**

Şengül CAN

**Danışman
Doç. Dr. Mustafa GERŞİL**

MANİSA–2022

YEMİN METNİ

Doktora tezi olarak sunduđum ““R” PROGRAMLAMA DİLİNDE TAHMİN EDİCİ VERİ MADENCİLİĐİ ALGORİTMALARININ MODELLENMESİ VE PERFORMANSLARININ KARŞILAŞTIRILMASI” adlı çalışmanın, tarafımdan bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurmaksızın yazıldığını ve yararlandığım eserlerin bibliyografyada gösterilen eserlerden oluştuđunu, bunlara atıf yapılarak yararlanmış olduđumu belirtir ve bunu onurumla dođrularım.

.../.../2022

Şengül CAN

İmza

ÖZET

“R” PROGRAMLAMA DİLİNDE TAHMİN EDİCİ VERİ MADENCİLİĞİ ALGORİTMALARININ MODELLENMESİ VE PERFORMANSLARININ KARŞILAŞTIRILMASI

Günümüz ekonomisi dinamik bir yapıdadır. Gelişen bilgi teknolojileriyle birlikte kayıt altında tutulan veri sayısı da artmıştır. Artan veri miktarı, veriler arasındaki sarmal ilişkileri görmeyi zorlaştırmaktadır. Ham veriden bilgi elde edilmesi ve elde edilen bilginin gelecek tahminlerinde kullanılması işletmeler için kritik öneme sahiptir. Veri tahmini kesinlik içermeyen ve karmaşık bir süreçtir. Ancak doğruya en yakın tahmin işletmelerin stratejik karar almasında oldukça önemlidir. Veri tahmini ekonomi alanında yaygın olarak kullanılmaktadır.

Bu çalışmada ekonomik kalkınma için büyük öneme sahip ihracat verileri incelenmiştir. Türkiye İstatistik Kurumu ve Merkez Bankası istatistikleri kullanılarak veri ambarı oluşturulmuştur. İstatistiksel analizlerde sıklıkla tercih edilen R programlama dili kullanılarak algoritmalar geliştirilmiştir. R programlama dilinde yapay sinir ağı, regresyon ve zaman serisi algoritmaları geliştirilmiştir. Çalışmanın birinci aşamasında; R programında yapay sinir ağı algoritması geliştirilmiştir. Bu aşamada farklı ağ topolojileri test edilerek en başarılı yapay sinir ağı belirlenmiştir. Buna göre (5,3) topolojisine sahip ağın en başarılı performansa sahip olduğu görülmüştür. Çalışmanın ikinci aşamasında R programında regresyon algoritması geliştirilmiştir. Çalışmanın son aşamasında R programında zaman serisi algoritması geliştirilmiştir. Naive Bayes ve ARIMA modelleri test edilmiş ve ARIMA(1,0,0)(2,0,0) modelinin daha başarılı olduğu görülmüştür.

Yapay sinir ağı (5,3), regresyon ve ARIMA(1,0,0)(2,0,0) algoritmaları veri ambarındaki eğitim verisi üzerinde denenmiştir. Algoritmaların başarıları istatistiksel hata oranları hesaplanarak karşılaştırılmıştır. Buna göre en başarılı tahmin algoritmasının yapay sinir ağı olduğu görülmüştür.

Anahtar Kelimeler: Veri Madenciliği, R Programlama, Tahmin Performansı Karşılaştırma

ABSTRACT

MODELING OF PREDICTIVE DATA MINING ALGORITHMS IN THE "R" PROGRAMMING LANGUAGE AND COMPARISON OF THEIR PERFORMANCES

Today's economy is dynamic. With the developing information technologies, the number of recorded data has also increased. The increasing amount of data makes it difficult to see the relationships among the data. Obtaining information from raw data and using the obtained information in future predictions are of critical importance for businesses. Data estimation is an imprecise and complex process. However, estimation which is the closest to right is very important for businesses to make strategic decision. Data forecasting is widely used in economics.

In this study, export data, which is of great importance for economic development, was examined. A data warehouse was created using statistics from the Turkish Statistical Institute and The Central Bank of the Republic of Turkey. Algorithms were developed using the R programming language, which is frequently preferred in statistical analysis. Artificial neural network, regression and time series algorithms were developed in R programming language. In the first stage of the study, an artificial neural network algorithm was developed in the R program. At this stage, different network topologies were tested and the most successful artificial neural network was determined. Accordingly, it was detected that the network with the (5,3) topology had the most successful performance. In the second stage of the study, a regression algorithm was developed in the R program. In the last stage of the study, the time series algorithm was developed in the R program. Naive Bayes and ARIMA models were tested and it was detected that the ARIMA(1,0,0)(2,0,0) model was more successful. Artificial neural network (5,3), regression and ARIMA(1,0,0)(2,0,0) algorithms were tested for the training data in the data warehouse. The success of the algorithms was compared by calculating the statistical error rates. Accordingly, it was concluded that the most successful prediction algorithm was the artificial neural network.

Keywords: Data Mining, R Programming, Prediction Performance

TEŞEKKÜR

Çalışmamın her aşamasında bana destek olan, bilgi ve deneyimleri ile yol gösteren danışman hocam Sayın Doç. Dr. Mustafa GERŞİL' e, bilgi ve tecrübesi ile lisansüstü öğrenim hayatımın tüm zorlu aşamalarında maddi manevi her yönden yardımcı olan, tecrübeleri ile beni aydınlatan ve desteğini hiç eksik etmeyen, kendilerini tanımaktan büyük onur duyduğum sevgili hocalarım Sayın Prof. Dr. Pınar MIZRAK ÖZFIRAT'a, Sayın Prof. Dr. Tuncer ÖZDİL'e ve Sayın Prof. Dr. Cengiz YILMAZ'a, çalışmalarım sırasında manevi desteğini her zaman hissettiğim değerli eşim Doç. Dr. Hüseyin CAN'a, desteğini her zaman gösteren kıymetli annem İpek ERGİN ve çok özlediğim canım babam Hamza ERGİN'e, varlığıyla beni hep mutlu eden canım kızım Esme Deniz CAN'a yürekten teşekkür ederim.

Şengül CAN
Manisa, 2022

İÇİNDEKİLER LİSTESİ

SİMGELER VE KISALTMALAR DİZİNİ	xii
TABLolar DİZİNİ	xiii
ŞEKİLLER DİZİNİ	xiv
EKLER LİSTESİ	xvi
GİRİŞ	1
BİRİNCİ BÖLÜM.....	3
1.1.DİŞ TİCARET NEDİR?	3
1.2.İHRACAT NEDİR?	8
1.3.ÜLKE İHRACAT PERFORMANSINI ETKİLEYEN TEMEL FAKTÖRLER	11
İKİNCİ BÖLÜM	14
VERİ AMBARI VE VERİ TAHMİN YÖNTEMLERİ.....	14
2.1.VERİ AMBARI	14
2.1.1. Veri Ambarı Katmanları.....	19
2.1.1.1. Veri Kaynağı Katmanı	20
2.1.1.2. Veri Aktarma Katmanı.....	20
2.1.1.3. Depolama Katmanı	21
2.1.1.4. Veri Katmanı.....	21
2.1.1.5. Analiz Katmanı	22
2.1.2. Veri Ambarında Yer Alan Verinin Kalitesi	23
2.2. VERİ TAHMİN YÖNTEMLERİ	28
2.2.1. Nitel Tahmin Teknikleri	29
2.2.1.1. Ekstrapolasyon.....	30
2.2.1.2. Delphi.....	30
2.2.1.3. Pearl Eğrisi.....	31
2.2.1.4. Trend Analizi	31
2.2.2. Nicel Tahmin Teknikleri	31
2.2.2.1. Sebep-Sonuç İlişkisine Dayanan Teknikler	35
2.2.2.1.1. Basit Doğrusal Regresyon	35
2.2.2.1.2. Çoklu Doğrusal Regresyon	36
2.2.2.1.3. Doğrusal Olmayan Regresyon	37
2.2.2.1.4. Vektör Otoregresyon.....	37

2.2.2.2. Korelasyon Katsayısı Analizi	38
2.2.2.3. Zaman Serisine Dayanan Tahmin Teknikleri	39
2.2.2.3.1. Hareketli Ortalamalar Süreci MA(q)	39
2.2.2.3.2. Ağırlıklı Ortalama Yöntemi.....	40
2.2.2.3.3. Üstel Düzeltme Yöntemi	40
2.2.2.3.4. Box-Jenkins Yöntemi	41
ÜÇÜNCÜ BÖLÜM	43
YAPAY SİNİR AĞLARI.....	43
3.1. SİNİR HÜCRESİ	45
3.2. YAPAY SİNİR HÜCRESİ	46
3.3. YAPAY SİNİR AĞININ ÖĞRENMESİ.....	48
3.3.1. Denetimli Öğrenme	48
3.3.2. Denetimsiz Öğrenme	50
3.3.3. Pekiştirmeli Öğrenme	51
3.4. YAPAY SİNİR AĞININ SINIFLANDIRILMASI.....	52
3.4.1. Yapılarına Göre Yapay Sinir Ağlarının Sınıflandırılması.....	52
3.4.1.1. İleri Beslemeli Yapay Sinir Ağı.....	52
3.4.1.2. Geri Yayılımlı Yapay Sinir Ağı.....	54
3.4.1.3. Tekrarlayan Yapay Sinir Ağı	55
3.4.2. Öğrenme Kurallarına Göre Yapay Sinir Ağlarının Sınıflandırılması.....	56
3.4.2.1. Hebb Öğrenim İlkesi.....	56
3.4.2.2. Delta Öğrenim İlkesi.....	56
3.4.2.3. Hopfield Öğrenim İlkesi	57
3.4.2.4. Kohonen Öğrenim İlkesi.....	57
3.4.2.5. Dereceli Azaltma (Gradient Descent) İlkesi	57
3.4.3. Öğrenme Algoritmalarına Göre Yapay Sinir Ağı Modelleri.....	58
3.4.3.1. Geri Yayılım (Backpropagation) Algoritması	58
3.4.3.2. Momentum Geri Yayılım Algoritması	58
3.4.3.3. Levenberg Marquardt Algoritması	59
3.4.3.4. Esnek Yayılım Algoritması	59
3.4.3.5. Hızlı Yayılım Algoritması	59
3.4.3.6. Delta-Bar-Delta Algoritması.....	60
3.4.3.7. Genişletilmiş Delta-Bar-Delta Algoritması	60

3.4.3.8. Genetik Algoritmalar	60
3.4.4. Topolojilerine Göre Yapay Sinir Ağlarının Sınıflandırılması.....	61
3.4.4.1. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağları	61
3.4.4.2. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı	62
3.4.4.3. Tekrarlı (Recurrent) Yapay Sinir Ağı.....	64
3.5. Yapay Sinir Ağlarının Kullanıldıkları Yerler.....	65
3.6. Yapay Sinir Ağlarının Olumlu ve Olumsuz Özellikleri	67
3.6.1. Yapay Sinir Ağlarının Olumlu Özellikleri.....	67
3.6.2. Yapay Sinir Ağlarının Olumsuz Özellikleri	67
3.7. Yapay Sinir Ağının Tasarımı.....	68
3.7.1. Öğrenme Algoritmasının Belirlenmesi	69
3.7.2. Yapay Sinir Ağının Gizli Katman Sayısının Tespit Edilmesi	70
3.7.3. Katmanlarda Yer Alan İşlem Eleman Sayısının Belirlenmesi.....	70
3.7.4. Yapay Sinir Ağının Parametre Seçimi.....	70
3.8.Yapay Sinir Ağlarının Tahminlemede Kullanımı	74
3.9. R Programlama Dili.....	77
DÖRDÜNCÜ BÖLÜM	79
R PROGRAMLAMA DİLİYLE TAHMİN PERFORMANSI	
KARŞILAŞTIRMASI.....	79
4.1. Veri Setinin Oluşturulması	82
4.2. R Yazılımında Yapay Sinir Ağı Geliştirilerek Optimal Modelin Belirlenmesi	86
4.3. R Programında Regresyon Modeli Geliştirilmesi	96
4.4. R Programında Zaman Serisi Modelinin Geliştirilmesi	98
4.5. Yapay Sinir Ağı, Regresyon ve Zaman Serisi Modellerinin Eğitim Verisi Üzerindeki Performanslarının Karşılaştırılması	102
SONUÇ.....	105
KAYNAKÇA	109

SİMGELER VE KISALTMALAR DİZİNİ

BPM	İş Performansı Yönetimi
CRM	Müşteri İlişkileri Yönetimi
DW	Durbin Watson Testi
ECG	Elektrokardiyografi
EEG	Elektroensefalografi
HKO	Hata karaler Ortalaması
HKT	Hata Karaler Toplamı
KOSGEB	Küçük ve Orta Ölçekli İşletmeleri Geliştirme ve Destekleme İdaresi Başkanlığı
LM	Levenberg Marquardt algoritması
LVQ	Learning Vector Quantization
MAE	Mean Absolute Error
MAPE	Mean Absolute Error
ME	Mean Error
MPE	Mean Percentage Error
MSE	Mean Squared Error
MSPE	Mean Squared Percent Error
OMHY	Ortalama Mutlak Hata Yüzdesi
RMSE	Root Mean Squared Error
RMSE	Root Mean Squared Error
SOM	Self Organization Map
VAR	Vektör Otoregresyon
XML	Extensible Markup Language
YSA	Yapay Sinir Ağı

TABLÖLER DİZİNİ

Tablo 1: Bölgeye Ve Seçilen Ekonomiye Göre Dünya Mal İhracatı, 2010-2020 (Milyon \$)	6
Tablo 2: Bölgeye Ve Seçilen Ekonomiye Göre Dünya Mal İthalatı, 2010-2020 (Milyon \$)	7
Tablo 3: Türkiye'nin Yıllara Göre Dış Ticareti (Bin \$)	8
Tablo 4: Türkiye'nin En Çok İhracat Yaptığı 10 Ülke	9
Tablo 5: Yapay Sinir Ağı Türlerinin Sınıflandırılması	69
Tablo 6: Öğrenme Algoritmalarının Kullanım Türleri	69
Tablo 7: Literatür Taraması	74
Tablo 8: Yapay Sinir Ağı Modellerinin Hata Oranları	91
Tablo 9: Mevsimsel Naive Model Hata Değerleri	100
Tablo 10: ARIMA(1,0,0)(2,0,0) Modeli Hata Değerleri	101
Tablo 11: Zaman Serisi Modelleri Hata Değerleri Karşılaştırması	102
Tablo 12: Tahmin Teknikleri Değerlendirme Ölçütleri	103
Tablo 13: Gerçekleşen ve Tahmin Edilen Değerler	103

ŞEKİLLER DİZİNİ

Şekil 1: Veri Ambarı Nedir?	14
Şekil 2: Veri Ambarı Girdi-Çıktı Şeması	18
Şekil 3: Veri Ambarı Mimarisi	20
Şekil 4: Veri Ambarında Veri Kalitesi Süreci	27
Şekil 5: Yapay Sinir Ağı Çalışma Prensipleri	44
Şekil 6: Biyolojik Bir Nöronun Bölümleri	46
Şekil 7: Yapay Sinir Hücresi	46
Şekil 8: İleri Beslemeli Yapay Sinir Ağı	53
Şekil 9: Geri Yayılımlı Yapay Sinir Ağı	54
Şekil 10: Tekrarlı Yapay Sinir Ağı	55
Şekil 11: Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı	62
Şekil 12: Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı	63
Şekil 13: Tekrarlı (Recurrent) ve Gizli Katmanlı Bulunmadığı Yapay Sinir Ağı	64
Şekil 14: Gizli Katmanlı Tekrarlı (Recurrent) Yapay Sinir Ağı	65
Şekil 15: Tahmin İçin Kullanılacak Veri Ambarı.....	82
Şekil 16: 2005-2019 Arası Üretim Endeksi (Aylık).....	83
Şekil 17: 2005-2019 Arası Sınai Kapanış Değerleri.....	83
Şekil 18: 2005-2019 Arası Döviz Alış Değerleri	84
Şekil 19: 2005-2019 Arası Teknoloji Endeksi Değerleri	84
Şekil 20: 2005-2019 Arası İhracat Endeksi Değerleri.....	85
Şekil 21: Normalize Edilmiş Veri Setinin Görünümü.....	85
Şekil 22: İki Gizli Katmanlı (4,2) Yapay Sinir Ağı.....	86
Şekil 23: İki Gizli Katmanlı (5,3) Yapay Sinir Ağı.....	87
Şekil 24: İki Gizli Katmanlı (6,4) Yapay Sinir Ağı.....	87
Şekil 25: İki Gizli Katmanlı (6,5) Yapay Sinir Ağı.....	88
Şekil 26: İki Gizli Katmanlı (8,3) Yapay Sinir Ağı.....	88
Şekil 27: İki Gizli Katmanlı(8,5) Yapay Sinir Ağı.....	89
Şekil 28: Üç Gizli Katmanlı (5,4,3) Yapay Sinir Ağı.....	89
Şekil 29: Üç Gizli Katmanlı (3,6,7) Yapay Sinir Ağı.....	90
Şekil 30: Üç Gizli Katmanlı (4,5,8) Yapay Sinir Ağı.....	90
Şekil 31: YSA(5,3) ile YSA(4,2) Ağlarının R Programında Grafiksel Olarak Karşılaştırılması	92
Şekil 32: YSA(5,3) ile YSA(6,4) Ağlarının R Programında Grafiksel Olarak Karşılaştırılması	92
Şekil 33: YSA(5,3) ile YSA(6,5) Ağlarının R Programında Grafiksel Olarak Karşılaştırılması	93
Şekil 34: YSA(5,3) ile YSA(8,3) Ağlarının R Programında Grafiksel Olarak Karşılaştırılması	93
Şekil 35: YSA(5,3) ile YSA(8,5) Ağlarının R Programında Grafiksel Olarak Karşılaştırılması	93

Şekil 36: YSA(5,3) ile YSA(5,4,3) Ağlarının R Programında Grafikselsel Olarak Karşılaştırılması	94
Şekil 37: YSA(5,3) ile YSA(3,6,7) Ağlarının R Programında Grafikselsel Olarak Karşılaştırılması	94
Şekil 38: YSA(5,3) ile YSA(4,5,8) Ağlarının R Programında Grafikselsel Olarak Karşılaştırılması	94
Şekil 39: Yapay Sinir Ağında Yer Alan Bağımsız Parametrelerin Önem Düzeyi	95
Şekil 40: İhracat Tutarı Regresyon Modeli	96
Şekil 41: Regresyon ve YSA Modellerinin Test Verisi Deneme Grafikleri	97
Şekil 42: Regresyon ve YSA Modellerinin Test Veri Üzerinde Birlikte Gösterimi .	97
Şekil 43: Otokorelasyon Grafiği	98
Şekil 44: Veri Setine Ait Trend İnceleme Grafiği	98
Şekil 45: ADF Testi Sonuçları.....	99
Şekil 46: Veri Setinin Farkı Alındıktan Sonra Durağanlık Kontrolü Grafikleri	99
Şekil 47: Durbin-Watson Test Sonuçları.....	100
Şekil 48: Mevsimsel Naive Model Eğitim Verisi Üzerindeki Başarısı	100
Şekil 49: Eğitim Verisi Üzerinde ARIMA Model Denemelerinin Sonuçları.....	101
Şekil 50: ARIMA(1,0,0)(2,0,0) Modelinin Eğitim Verisi Üzerindeki Tahmin Başarısı	101
Şekil 51: Gerçek-Tahmin Değeri Karşılaştırmalı Grafiği	104

EKLER LİSTESİ

EK 1: R İle Geliştirilen Algoritmaların Kodları



GİRİŞ

Varoluşundan günümüze kadar insanlar ticaretle iç içedir. Öncesinde mal veya hizmet takası ile başlayan süreç; kıymetli madenler, para hatta günümüzde dijital paraya dönüşen farklı takas araçlarıyla gerçekleştirilmiştir (Süygün, 2021: 4). İnsanlığın yaşamını devam ettirmek için kullandığı ticaret, geçmiş çağlardan bu güne kadar tarihi şekillendirmiş, farklı kültürler ve yaşam biçimlerinin oluşmasına katkı sağlamıştır. Ticaretin ülkelerarası bir boyuta taşınması ise 1500’lü yıllardan başlamış ancak 1945 yılından itibaren uluslararası ticaretten bahsedebilmek mümkün hale gelmiştir (Emeksiz Dünder, 2021: 5).

Dünya çapında küreselleşen ekonomi, uluslararası ticaretin önemini arttırmış ve Türkiye’de 2000’li yıllardan itibaren dış ticaret artan bir ivme yakalamıştır (Deliçay, 2015). Bu küresel ekonomiler içerisinde ülkelerin rekabet gücü; ülke içerisindeki firmaların hem iç hem de dış piyasalardaki etkinliği ve oluşturduğu katma değer ile ölçülmektedir (Yücel, 2006: 5). Makroekonomik bir gösterge olan ihracat, ekonomik politika ve stratejilerin belirlenmesinde önemli bir faktördür. Bu nedenle ihracat verilerine yönelik tahminlerin en hızlı ve doğru biçimde yapılabilmesi makroekonomik stratejilerin belirlenebilmesi açısından da oldukça önemlidir. Bu açıdan ihracat verisi ile ilgili tahminler ülkelerin; büyüme, gelişme ve kalkınma gibi hedeflerine yönelik yapılan stratejilerde etkilidir (Turaç, 2020: 1).

Gelecek stratejilerle ilgili en doğru kararı alabilmek; karar alma sürecine etkisi olan değişkenlerin doğru tespit edilmesi ve belirlenen değişkenlerin etkisinin gerçeğe en yakın biçimde ölçülmesi olarak tanımlanan başarılı bir tahmin süreciyle gerçekleşmektedir. Başarılı, hızlı ve doğru bir tahmin gerçekleştirebilmek için tercih edilen modelin performansı oldukça belirleyicidir. Modelleme ve öngörü araştırmalarında kullanılan pek çok istatistiksel ve ekonometrik teknik bulunmaktadır. Ancak son yıllarda yapay sinir ağları yönteminin öngörü çalışmalarında yaygın biçimde tercih edilmekte ve başarılı sonuçlar verdiği görülmektedir. İnsan beyniyle benzer yapıda çalışmaları, düzensiz veri kullanarak öğrenmeleri, anlamlandırabilmeleri ve genelleme yapabilmeleriyle geleneksel analiz tekniklerinden daha avantajlı olan yapay sinir ağları hem doğrusal hem de doğrusal olmayan problemlerin çözümlerinde büyük avantaj sağlayabilmektedir. Günümüzde

yapay sinir ağıları; tahmin, sınıflandırma, optimizasyon, örüntü tanımlama ve makine öğrenmesi gibi alanlarda kullanılmaktadır (Özçalıcı ve Ayriçay, 2016; Vural, 2008).

Bu tez kapsamında; ülkelerin ekonomik alandaki stratejik kararlarında oldukça önemli bir yere sahip olan ihracat verisinin tahmin edilmesinde, farklı tahmin yöntemleri karşılaştırılarak en doğru tahmini hata payı en düşük olacak şekilde tahmin eden yöntem belirlenmiştir. Bu kapsamda ilk olarak dış ticaret ve ihracat kavramlarından bahsedilerek; ihracatı etkileyen faktörlerin neler olduğu belirlenmiştir. İkinci bölümde veri ambarı hakkında bilgi verilerek klasik veri tahmin teknikleri tanıtılmıştır. Çalışmanın üçüncü bölümünde Yapay Sinir Ağları tekniği ile ilgili detaylı bilgiler verilmiştir. Çalışmanın dördüncü bölümünde ise Türkiye İstatistik Kurumu ve Merkez Bankaları web sayfalarında yayınlanan istatistik verileri kullanarak veri ambarı oluşturulmuştur. R programlama dilinde yapay sinir ağı, regresyon ve zaman serisi algoritmaları geliştirilerek veri ambarı üzerinde her üç tekniğin optimal modeli belirlenmiştir. Optimal modeli belirlenen teknikler ile veri tahmini gerçekleştirildikten sonra algoritmaların performansları istatistik hata kriterleri ile karşılaştırılmıştır. Çalışmanın son bölümünde ise elde edilen sonuçlar karşılaştırılmış ve geleceğe yönelik tahminleme yapılmıştır.

BİRİNCİ BÖLÜM

1.1.DIŞ TİCARET NEDİR?

İki veya daha fazla ülke arasında gerçekleştirilen mal ve hizmet alım-satım olarak tanımlanan dış ticaret; ihracat ve ithalat olmak üzere iki yönlüdür (Saygılıoğlu ve Akçin, 2018: 29). Ülkeler arasında gerçekleştirilen ekonomik işlemler olarak tanımlanan uluslararası ticaret kalemleri içerisinde yaygın olarak tüketim malları, hammadde ve gıda ürünleri bulunmaktadır. Uluslararası ticarete maddi işlemler; merkez bankaları veya özel bankaların önemli rol oynadığı finansal ödemelerle kolaylaştırılmaktadır. Uluslararası ticaret ve beraberindeki mali işlemler genellikle bir ulusun bolca ürettiklerine karşılık yoksun olduğu malları sağlamak amacıyla yürütülmektedir. Beraberinde getirdiği ekonomik politikalarla birlikte işleyen bu tür işlemler; bir ulusun yaşam standardını iyileştirme eğilimindedir. Modern uluslararası ilişkiler tarihi ağırlıklı olarak uluslararası serbest ticareti teşvik etme çabalarıyla ilgilidir (Robinson vd. 2020; 1).

Farklı halklar arasında mal ve hizmet takası yapılması, muhtemelen insanlık tarihi kadar eskidir. Bunun yanı sıra uluslararası ticaret özellikle farklı ulusların üyeleri arasındaki değişimi ifade eder ve bu sistem ancak Orta Avrupa’da modern ulus devletin yükselmesiyle başlamaktadır (Robinson vd. 2020; 1).

Dış ticaret; işletmelerin her türlü yurtdışı faaliyetlerini kapsamaktadır. Bu sayede üretici ve tüketicilerin diğer ülkelerdeki mal ve hizmetler hakkında bilgi sahibi olması firmaları uluslararası arenada faaliyet göstermeye yönlendirmektedir. Dahası işletmelerin sahip olmadıkları mal/hizmetleri dış ülkelere almalara olanak tanıyan uluslararası ticaret, hem işletmeler hem de ülkeler için gelir ve istihdamda pozitif bir etkiye sahiptir (Seyoum, 2009).

Ülkemizde uluslararası ticaret kavramının gelişimi 1980 sonrasında uygulanmaya başlanan döviz kuru politikası ile üç dönemde incelenmektedir (Polat, 2019: 36);

- Birinci Dönem: 1980-1989 arasında istikrara yönelik önlemler alınırken aynı zamanda ekonomi de serbest modele geçilerek döviz kullanımı üzerindeki kontroller kaldırılmıştır. Tarım destekleri azaltılarak ithal ikame politikası yerine ihracat temelli ve dışa dönük bir ekonomik model benimsenmiştir.

- İkinci Dönem: 1990 yılıyla birlikte uygulanan sıcak para politikasıyla yurt içinde yetersiz kalan tasarruf kaynaklı oluşan kamu açıklarının kapatılması hedeflenmiştir. 1999 yılına kadar Türkiye ekonomisi yüksek enflasyon rakamları nedeniyle gerek sosyal gerekse ekonomik açıdan önemli sorunlarla karşılaşmıştır.
- Üçüncü Dönem: 2001 yılında ise ekonomik kriz etkilerinin yoğun yaşandığı ve dalgalı döviz kurunun kullanıldığı bir dönem olmuştur. Türkiye’de döviz kurunun yüksek olması ara malların ithalatının tercih edilmesi ve bu malların dayanıklı tüketim mallarının üretiminde kullanılarak yurtdışı satışlarının yapılması nedeniyle ihracat ithalata bağımlı hale gelmesine neden olmuştur.
- Günümüz: 2015 yılı itibariyle ülkemize dışardan gelen toplam sermaye miktarı 11.778 milyon dolar iken en büyük pay 6.785 milyon dolar ile Avrupa Birliğine aittir. İkinci sırada en çok pay sahibi grup ise Asya Ülkeleridir. Yine 2015 ve sonrasında Türkiye tarımsal faaliyetleri AB ile uyumlu bulunmuştur (Özdemir ve Koç-Aytemin; 2016). Genel anlamda değeriendirilecek olursa Türkiye ekonomisi 2000 yılı sonrası makroekonmik göstergeler konusunda önemli gelişmeler göstermiştir. Bununla birlikte büyüme performansı dalgalı seyir izlemekte ve büyümenin dış talebe bağılı olması ekonomiyi olumsuz etkilemektedir (Sungur, 2015: 262).

Firmaların global pazarda ihracat faaliyeti içerisinde olmasının ülke ekonomileri içerisindeki yeri oldukça önemlidir. Bu nedenle hükümetler uluslararası ticareti desteklemek ya da kısıtlamak için farklı yöntemlere başvurmaktadır. Dış ticaret politikası olarak tanımlanan bu yöntemlerin cari açığın kapatılması, hazineye gelir sağlanması, iktisadi kalkınmanın sağlanması, yerel sanayide uluslararası rekabete karşı koyulması, yerel pazarda fiyat istikrarının sağlanması, siyasi işbirliklerinin sağlanması, ülkelerin kendi kendine yetebilmesi gibi amaçları bulunmaktadır (Emeksiz Dünder, 2021: 11).

Uluslararası ticaret kavramı bir ülkenin ekonomisi üzerinde kısa vadede dış borçları finanse ederken, uzun vadede ise ekonominin etkin kaynak dağılımını sağlamaktadır. Bu faydaların sağlanabilmesi için ihracatın ithalattan fazla olması gerekmektedir (Gürbüzer, 2019: 86).

Uluslararası ticaret süreçleri, çeşitli risklere sahip olmasına rağmen hükümetler aracılığıyla desteklenmekte ve firmalar tarafından da tercih edilmektedir. Özellikle Türkiye gibi gelişmekte olan ülkelerin uluslararası ticareti teşvik etme nedenleri içerisinde (Brohman, 1996: 50);

- Gelişmekte olan ülkelerdeki iç talep seviyesinin düşük olması ve bazı sektörlerde büyümenin ağırlıklı olarak (ekonomik stratejilerin dışa dönük olması nedeniyle) küresel pazara erişimle bağlantılı olması,
- Uluslararası ticaret gibi dışa dönük stratejilerin mikroekonomik verimlilik bakımından en düşük seviyede zararlı stratejiler olarak kabul edilmesi,
- Gerek uluslararası ticaret gerekse turizm ağırlıklı stratejilerin hem üretim miktarı ve istihdamı arttırarak uzun vadede ekonomik büyümeyi kolaylaştırması,
- Gerek ihracat gerekse turizm kaynaklı gelirlerin, uluslararası finansal piyasalar açısından olumlu görülmesi dolayısıyla daha kolay bir dış ticaret ve dış hesap dengesi oluşturarak makroekonomik anlamda istikrar sağlaması,
- Uluslararası ticaretten sağlanan kazançların sermaye malları ve ithal mallar için döviz sermayesi oluşturması,
- Uluslararası alanlardaki artan hacim ve pazardaki rekabetin ölçek ekonomisi ve ekonomik verimlilik üzerine olumlu etkileri bulunmaktadır.

Ülke ekonomisine olan katkısı ve önemi nedeniyle uluslararası ticaret en yoğun desteklenen alanların başında gelmektedir. Türkiye’de Ticaret Bakanlığı, KOSGEB gibi kurumların sunduğu desteklerle uluslararası ticaret alanında teşvik edici uygulamalar bulunmaktadır. Ayrıca sağladığı faydalar nedeniyle de işletmeler uluslararası ticareti zaten tercih etmekte ve uluslararası ticaret hacimlerini arttırmak için çalışmaktadır. Satış miktarı ve karlılığını arttırmak, küresel pazarda pay sahibi olmak, iç pazardaki bağımlılığı azaltmak ve dalgalanmadan korunmak, atıl üretim kapasitesini arttırabilmek, rekabet etme kapasitesini arttırabilmek, istihdamı arttırmak ve yurt içine döviz girdisi sağlanması firmaları uluslararası ticaret yapmaya yöneltten başlıca sebeplerdendir (Sakarya, 2009: 119).

Uluslararası ticaretin makro açıdan ülke ekonomileri için mikro açıdan da firmalar için oldukça fazla avantajı bulunmaktadır. Ülkeler bu nedenle uluslararası ticareti özendirmek için farklı stratejiler uygulamaktadır. Türkiye’de özellikle 1980 yılı sonrasında ikameci sanayileşme stratejisi yerini uluslararası ticarete yönelik sanayileşme stratejisine bırakmıştır (Süyğün, 2021: 8).

Tablo 1: Bölgeye Ve Seçilen Ekonomiye Göre Dünya Mal İhracatı, 2010-2020 (Milyon \$)

	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
Dünya Geneli	15303993	18343601	18514486	18969946	19011072	16558147	16045249	17742931	19550439	19014680	17582919
Avrupa	5707128	6726230	6538551	6856966	6875790	6009471	5991440	6555200	7181446	6986663	6525745
Arnavutluk	1544	1947	1967	2339	2429	1917	1959	2292	2870	2716	2506
Avusturya	152560	177428	166611	175156	178223	152728	152090	168026	184815	178670	168940
Belçika	407692	475672	445939	468760	472192	396841	398134	429645	468650	446944	419340
Bosna Hersek	4803	5850	5162	5687	5892	5098	5328	6402	7182	6578	6152
Bulgaristan	20630	28208	26686	29579	29245	25371	26572	31438	33617	33340	31826
Hırvatistan	11806	13338	12371	12659	13835	12925	13813	16069	17402	17180	17069
Kıbrıs	1402	1818	1740	2019	3163	3295	2965	3288	5052	3453	3056
Çekya	132982	162939	157041	162274	175021	157878	162692	182142	202238	199128	191685
Danimarka	96440	111864	105469	110949	111493	95457	95326	102506	109711	110779	108074
Estonya	11591	16709	16087	16320	16042	12836	13171	14559	17017	16111	16375
Faeroe Adaları	839	1008	952	1087	1110	1023	1202	1329	1271	1430	1283
Finlandiya	69518	79142	73077	74437	74333	59817	57908	68073	75869	73468	66060
Fransa	523767	596473	568708	580963	581393	506264	501179	535298	582222	570951	488345
Almanya	1258924	1473985	1401113	1445067	1494214	1326206	1334355	1448191	1560539	1489412	1380000
Yunanistan	28017	33779	35324	36140	35960	28554	28151	32627	39502	37907	35094
Macaristan	95483	112312	103570	107503	110622	98524	101919	113806	124705	123796	120365
İzlanda	4604	5347	5064	4998	5053	4732	4436	4878	5556	5223	4586
İrlanda	116497	125740	116773	116637	121057	123361	130864	137359	164794	169583	178732
İtalya	447301	523258	501306	518268	529797	456990	461737	507418	549526	537718	496108
Litvanya	9532	13130	14112	14467	14715	12286	12294	14126	16166	15705	16178
Letonya	20748	28050	29611	32598	32319	25392	25010	29901	33337	33151	32767
Lüksemburg	19748	20866	18833	18441	19099	17139	15796	15761	16412	16464	13799
Malta	3586	4386	4250	3637	2929	2607	3186	2858	3192	3007	2679
Montenegro	437	628	469	498	441	352	361	421	472	465	419
Hollanda	574251	667101	655374	671556	672410	570442	570606	652065	726697	708596	674475
Kuzey Makedonya	3351	4478	4015	4299	4969	4536	4790	5668	6911	7189	6635
Norveç	130657	160410	160953	156022	144677	103915	88410	101054	121791	102799	84459
Polonya	159724	188696	185374	204984	220052	199124	203817	234364	263569	266595	271070
Portekiz	49406	59617	58090	62823	63832	55047	55372	62130	68361	67063	61509
Romanya	49579	63035	57841	65835	69725	60595	63534	70761	79660	76867	70720
Sırbistan	9795	11779	11229	14614	14845	13376	14874	16992	19227	19630	19498
Slovakya	65957	79736	80721	85701	86227	75146	77060	83414	93425	89509	86192
Slovenya	29200	34682	32163	34019	35956	31929	32917	38443	44200	44943	44777
İspanya	254418	306551	295250	317833	324533	282274	289981	319531	346754	334018	306995
İsveç	158549	186963	172345	167550	164645	140023	139290	152920	165968	160576	155537
İsviçre	195609	234819	312464	357852	311204	289720	302900	299603	310749	313934	319232
Türkiye	113883	134907	152462	161481	166505	150982	149247	164495	177169	180833	169482
Ukrayna	51478	68460	68530	64338	53901	38127	36360	43265	47348	50066	49220
Birleşik Krallık	420182	510380	478780	546755	510789	465850	410856	440997	486439	469684	403319
Avrupa Birliği	4767971	5587162	5342467	5535309	5653032	4929053	4969739	5466719	5993402	5824935	5457769
AB Dışı İhracat	1901000	2260831	2275655	2363804	2385603	2080189	2065528	2253396	2432357	2385999	2208879

Kaynak: https://www.wto.org/english/res_e/statistics_e/wts2021_e/wts2021chapter05_e.pdf

Tablo 2: Bölgeye Ve Seçilen Ekonomiye Göre Dünya Mal İthalatı, 2010-2020 (Milyon \$)

	2010	2011	2012	2013	2014	2015	2016	2017	2018	2019	2020
Dünya Geneli	15438092	18438364	18657296	18966119	19060809	16733507	16211194	17985896	19836342	19284167	17812107
Avrupa	5871148	6914827	6624439	6722646	6769935	5868444	5893900	6500775	7146039	6939577	6478191
Arnavutluk	4406	5383	4879	4920	5222	4302	4613	5271	5925	5897	5570
Avusturya	159009	191417	178513	183277	182076	156046	157697	175755	193722	184758	171964
Belçika	391177	466943	439128	451677	453700	375530	379409	409220	454947	427708	394637
Bosna Hersek	9223	11051	10019	10295	10988	8986	9146	10504	11630	11159	9873
Bulgaristan	25513	32582	32710	34303	34651	29205	28933	34184	37856	37663	34829
Hırvatistan	20067	22663	20832	22022	22809	20571	21903	24829	28203	28160	26649
Kıbrıs	8569	8678	7296	6314	7996	7023	7830	9231	10815	9127	8636
Çekya	126652	152125	141412	144259	154237	141364	143040	163352	184659	179039	170142
Danimarka	83052	95663	91925	97348	99572	85623	85513	92957	102605	97824	96782
Estonya	12287	17459	18085	18464	18296	14521	14959	16674	19140	18022	17335
Faeroe Adaları	780	987	1153	1115	1051	910	980	1100	1227	1222	1240
Finlandiya	68803	84264	76468	77570	76765	60430	60841	70586	78624	73716	67731
Fransa	611070	720028	674415	681467	676617	570758	567657	619334	676441	654658	582351
Almanya	1054814	1254869	1154852	1181233	1207193	1051132	1055326	1162907	1284353	1233978	1170787
Yunanistan	65907	66705	61686	60859	61983	46786	46809	53495	63877	62510	55513
Macaristan	88178	102440	95176	100111	104897	91973	93880	107519	120741	120590	115480
İzlanda	3920	4841	4772	5020	5375	5299	5670	6965	7679	6567	5698
İrlanda	60276	66606	62769	72134	82016	76977	81185	93198	107669	100757	97969
İtalya	487049	558787	488600	479447	474394	410919	406788	453122	503240	475006	422879
Litvanya	11691	16290	17227	17865	17964	14719	14434	17033	19681	18959	18292
Letonya	23403	31773	31965	34806	34359	28154	27376	32258	36502	35759	33140
Lüksemburg	25092	28860	27543	26692	26656	23289	21872	22876	24175	24246	20814
Malta	5062	6293	6598	6142	6798	6036	6444	5997	6769	7072	5212
Montenegro	2182	2544	2336	2354	2369	2040	2286	2613	3010	2909	2402
Hollanda	516409	594366	586927	589697	589570	512105	500797	574646	645502	635678	596746
Kuzey Makedonya	5474	7027	6522	6620	7301	6427	6758	7723	9050	9471	8710
Norveç	77330	90784	87308	89808	89460	76424	72110	81249	86600	85319	80447
Polonya	178049	210597	199060	207607	223556	196473	199506	233812	268959	265282	257168
Portekiz	77749	82896	72429	75719	78389	66914	67954	78763	89060	89538	77515
Romanya	62109	76480	70207	73481	77748	69824	74560	85486	97747	96544	92122
Sırbistan	16735	19862	18925	20543	20601	17876	19245	21947	25882	26730	26233
Slovakya	66615	80187	77443	81915	81549	72837	74680	81617	92902	90001	84468
Slovenya	30094	35531	32035	33373	33934	29815	30537	36078	42267	44007	42121
İspanya	327016	376606	337338	340598	358860	311851	310921	351981	390562	372750	324993
İsveç	148946	177026	164436	160609	162211	138398	141021	154215	170605	158971	149163
İsviçre	176281	208220	295961	321509	275741	253027	270128	269834	279528	277830	291442
Türkiye	185544	240842	236545	260823	251142	213619	202189	238715	231152	210345	219397
Ukrayna	60911	82594	84639	76787	54430	37517	39252	49609	57046	60607	53929
Birleşik Krallık	592271	680939	702840	662160	694126	630003	636731	641002	672267	695798	634710
Avrupa Birliği	4732170	5564556	5178265	5261244	5348793	4609273	4621875	5161124	5751623	5542321	5135439
AB Dışı İhracat	1948784	2319427	2188553	2165741	2160164	1828018	1772801	2000932	2256936	2172103	1957723

Kaynak: https://www.wto.org/english/res_e/statis_e/wts2021_e/wts2021chapter05_e.pdf

1.2.İHRACAT NEDİR?

Günümüz modern toplumunda ekonominin küreselleşmesi ve bilgi ekonomisinde yaşanan gelişmeler insan hayatını yeniden şekillendirmiştir. Bilim ve teknolojiye günümüz koşullarında ulaşılan seviye ile insan yaşamındaki refah ve konfor arttırırken, ülkeler arasındaki ekonomik rekabetin de farklı boyutlara taşınmasına neden olmuştur. Küresel pazarda var olabilmek ve yeni pazarlara da açılabilmek için uluslararası rekabet firmalar için oldukça önemlidir (Maden ve Özcan, 2021: 47). Mal veya hizmetin harici pazarda satışa sunulması bedelinin ülkeye getirilmesi ihracat olarak tanımlanmaktadır. Gümrük mevzuatı kapsamında; ihraç edilecek ürünü kontrol etme, yükleme ve taşıma süreçlerinin gerçekleştirilerek dış pazarda satılması ve satış sonrasında mal veya hizmet bedelinin ülkenin değişim mevzuatı doğrultusunda getirilmesi olarak tanımlanmaktadır (Dölek, 2006: 73).

Ülke yönetimlerinin yasal mal ve hizmetlerin uygun doküman ve taşıma yöntemiyle hedef pazara ve tüketiciye ulaştırılması olarakta tanımlanan ihracat faaliyetleri, ülkelerin ürettikleri mal ve hizmetleri uluslararası rekabete uygun seviyeye getirmesi ve dünya ekonomisinden daha fazla faydalanabilme işlemidir. İhracat süreci; ürünün uluslararası standartlara uygun olarak üretilmesinden, yurtdışında pazarlanmasına, reklam ve tutundurma süreçlerinin gerçekleştirilmesine, dış satış işlemleri, uygun taşıma koşullarının sağlanması, dış satım yapılacak ülkenin mevzuat gerekliliklerinin zamanında yerine getirilmesi, ürünün istenilen yer ve zamanda teslimat işlemlerinin gerçekleştirilmesi gibi pek çok aşaması bulunmaktadır (İpek, 2015: 11).

Tablo 3: Türkiye'nin Yıllara Göre Dış Ticareti (Bin \$)

İhracat			İthalat		Dış Ticaret Dengesi	Dış Ticaret Hacmi	İhracatın İthalatı Karşılama Oranı
Yıllar	Değer	Değişim	Değer	Değişim	Değer	Değer	
2013	161480914,7		260822803		-99341888,3	422303717,7	61,91211537
2014	166504861,8	3,111170817	251142429,2	-3,711475257	-84637567,41	417647291	66,29897717
2015	150982113,8	-9,322699567	213619211,5	-14,94101091	-62637097,69	364601325,2	70,67815331
2016	149246999,3	-1,149218579	202189241,9	-5,350628119	-52942242,6	351436241,1	73,81549972
2017	164494619,3	10,21636624	238715127,9	18,06519759	-74220508,6	403209747,2	68,9083347
2018	177168756,3	7,704894558	231152482,6	-3,168062843	-53983726,36	408321238,9	76,64583753
2019	180832721,7	2,068065211	210345202,6	-9,001538662	-29512480,85	391177924,3	85,96950133
2020	169637755,3	-6,190785764	219516806,8	4,360263117	-49879051,53	389154562,1	77,27779834

Kaynak: <https://data.tuik.gov.tr/Bulten/Index?p=Dis-Ticaret-Istatistikleri-Temmuz-2021-37419>

Tablo 4: Türkiye'nin En Çok İhracat Yaptığı 10 Ülke

Milyon(\$)	2014	2015	2016	2017	2018	2019	2020
Çin	24,91	24,87	25,44	23,37	20,71	19,12	23,01
Almanya	22,6	21,35	21,47	21,3	20,4	19,27	21,71
Rusya	25,28	20,4	15,11	19,51	21,98	23,16	17,85
A.B.D.	21,72	11,14	10,86	11,95	12,37	12,15	11,84
İtalya	12,05	10,63	10,21	11,3	10,15	9,34	9,18
İran	9,83	6,09	4,69	7,49	6,93	4,69	7,04
Fransa	8,12	7,59	7,36	8,07	7,41	6,78	6,97
Hindistan	6,89	5,61	5,75	6,21	7,53	6,63	6,63
Güney Kore	7,54	7,05	6,38	6,6	6,34	5,77	6,63
İngiltere	5,93	5,54	5,32	6,54	7,44	5,63	5,57

Kaynak: <https://data.tuik.gov.tr/Bulten/Index?p=Dis-Ticaret-Istatistikleri-Temmuz-2021-37419>

Günümüz küresel ekonomilerinde uluslararası ticaret oldukça önem kazanmıştır. Türkiye’de 2000 yılından itibaren ivme kazanan dış ticaret hacminin ortalama 380 milyar dolar olduğu görülmektedir (Emeksiz Dünder, 2021: 15). Türkiye’nin en çok ihracat yaptığı ülkeler içerisinde Tablo 4’te görüldüğü gibi Çin, Almanya, Rusya ve A.B.D gelmektedir.

Tarihsel açıdan bakıldığında ülkelerin kalkınma aşamalarında sanayileşme sonrası dışarıdan aldıkları ürünleri ülke içerisinde üretmeye başlamakla olduğu bilinmektedir. İthal ikame stratejisine dayanan bu kalkınma aşamaları daha sonra serbest ticaret uygulamalarıyla yerini ihracata dayanan bir yaklaşıma bırakmıştır. Ülke ekonomilerinin büyümesi ithal ikame stratejisi kapsamında üretilen mal/hizmetler, dış talepler doğrultusunda üretilen mal ve hizmetler ya da tamamen iç piyasa talepleri çerçevesinde üretilen mal ve hizmetler ile şekillenmektedir. Bu kavramların ilk ikisi dış ticaret ile diğeri ise ülke içerisinde tüketilen mal/hizmetlerle alakalıdır (Yetgin, 2020: 11).

Böylece, ülkelerin ihracat oranının gayri safi yurtiçi hâsıla içerisindeki payının artması ihracata yönelik büyümedeki en önemli göstergedir. İthal ikame stratejisinin aksine tüm ürünlere yönelik olmayan bu strateji; sadece geliştirilerek ülke dışındaki rakipleriyle yarışabilecek ürünlere yöneliktir. Sanayileşme politikasının ihracata yönelik olması korumacı politikalara yer bırakmamaktadır ve tüm dünya işletmenin pazarı olarak görülmektedir. Böylece tüm dünya bir rekabet ortamı olduğu için işletmeler sürekli kaliteyi artırma faaliyetleri içerisinde. Dahası ihracat arttıkça makro seviyede ölçek ekonomisi oluşturarak verimlilik artışı da sağlamaktadır (Helpman ve Kurgman, 1985).

Dünya genelinde yaşanan olaylara paralel olarak dış ticaretin serbestliği, literatüre ihracat ve ekonomik büyüme ilişkisini kazandırmıştır. İkinci Dünya Savaşı sonrasında ekonomistlerin en çok ilgilendiği konulardan birisi haline gelen ihracat ve

ekonomik büyüme kavramı kalkınma literatüründe önemli bir hale gelmiştir. Ülke yönetimlerinin tercih ettikleri politikalar dolayısıyla ihracatın artması, ekonomik büyüme oranını pozitif yönde arttırmaktadır. Dışa kapalı ekonomilerin pek çok eksikliğini de ortaya çıkaran ihracata dayalı büyüme stratejileri yerli ekonomiyi dış ekonomilere açık hale getirmektedir. Böylece ekonomik büyüme dış ticarete dayandırılmaktadır. Yerel ekonomiyle üretilen malların ihracatının teşvik edilmesi ekonomik büyümeye olan pozitif etkilerinin hangi yöntem ile gerçekleştirileceği, ihracata dayalı büyüme stratejileri kapsamında yer almaktadır (Güven, 2021: 64).

İlk olarak dış ticaret faaliyetleri sonucu elde edilen döviz gelirleri ve katma değeri yüksek ürünlerin ve sermaye mallarının ithalatını mümkün hale getirmek gibi uygulamalar sonucunda; ihracatın ekonomi üzerinde büyüme yönlü bir etkisi olmaktadır (Doyle, 2001: 32). İhracatta yaşanan artış, istihdam ve üretimde genişlemeye neden olmaktadır. İhracatın artması sonucunda piyasalarda görülen rekabet ortamı yenilikleri uygulayıp bunlara uyum sağlamayı ve yenilik geliştirerek maliyetleri de azaltma yönünde zorlayıcı bir güç meydana getirmektedir. Üretkenliği artan ve ihracat yapmaya uygun olan kaynakların dağılımı ile yüksek katma değerli ürünlerde uzmanlaşarak ekonomik rekabet etkinliği ve verimliliği artmaktadır. İhracatın artması sonucu pazarda görülen genişleme ve artan rekabet ortamı ölçek ekonomisinden sağlanan faydayı ve bilgi birikiminde görülen artışa olumlu biçimde yansımaktadır. Ülke yönetimlerinin izledikleri dışa açık politikalar; iyi yönetim, ileri teknolojilerin uygulanması ve öğrenilmesi sonucu kazanımı sağlanan bilginin erişimini kolaylaştırarak ülke ekonomisi üzerindeki etkinliğini arttırmaktadır (Güven, 2021: 64).

Artan pazar rekabeti ile yurt içindeki doğal kaynak ve insan sermayesinin maksimum verimde kullanılmasına imkân sunarak ülke ekonomisinde ciddi bir büyüme hedefi yakalanmaktadır. Bu nedenle ülke yönetimleri işletme veya sektör bazında ihracatı teşvik uygulamaları yürütmektedir. Ülke yönetimleri genellikle risk ve belirsizliğin yüksek olduğu ihracat ortamında işletmelere uygun güvence ortamlarının sağlanmasına yönelik politikalar geliştirirler. Ayrıca ihracat ekonomisinin oluşturduğu rekabet istihdam maliyetlerinin düşmesi ve ülke içerisinde yapılan üretime olan talebin artması ve uzmanlaşma seviyesinin de yükselmesine neden olmaktadır. Ticaretin serbest olması ekonomik krizler nedeniyle zora giren ülke içi ekonomiler için önemli bir avantajdır. Yine ihracat yapan ülkelerde ülke ekonomilerine döviz girdisi yüksek olması nedeniyle ödeme dengesi kurulması

aısından b y k avantaj saėlamaktadır. Kazanılan d viz girdileri ile  lke ierisinde bulunmayan veya  retilmeyen ara ve sermaye mallarının ithalatına ve  lke ierisindeki  retim miktarını arttırmak iin  nem arz eden ihracat kapasitesinin geniřletilmesini saėlayan bu durum sonu olarak ekonomik b y meyi beraberinde getirmektedir (Yetgin, 2020: 12).

1.3. LKE İHRACAT PERFORMANSINI ETKİLEYEN TEMEL FAKT RLER

K resel pazarda rekabet etmeyi hedefleyen firmalar iin ihracat bařlangı noktasıdır. Gerek  lke ekonomisine olan katkısı gerekse refah seviyesini arttırmadaki  nemli rol  nedeniyle ihracat hem  lke ekonomisi hem de firmalar iin olduka  nemli bir yere sahiptir. Bir firmanın g sterdiėi ihracat performansı firma ierisinden veya dıřından pek ok fakt rle iliřkilidir (S yg n, 2021: 11). Genel olarak t m d nya  lkeleri ihracat seviyesini s rekli arttırarak ekonomik anlamda daha da g lenmeye alıřmaktadırlar.  lkenin yapılan ihracattan faydalanma seviyesi  lkede  retilen  r n sayısıyla iliřkilidir. (Emeksiz D ndar, 2021:33).

Pek ok alanda, iřletmelerin ihracat performansını nelerin etkilediėi ve bu etkenlerin  l lmesinde hangi y ntemlerin kullanıldıėı ayrıca ihracat performansını belirleyen fakt rlerin neler olduėuyla ilgilenilmektedir. Tanımı ve  l lmesi konusunda bir fikir birliėi bulunmayan ihracat performansı kavramı  zerine ok miktarda arařtırma bulunmakla birlikte  zellikle hangi fakt rlerden etkilendiėi veya nasıl  l ld ė yle ilgili g r ř ayrılıkları bulunmaktadır (Aaby ve Slater, 1989: 7; Zou ve Stan, 1998; 38).

Genel kullanımda farklı tanımları bulunmakla birlikte; ihracat yapan iřletmelerin k resel pazardaki stratejik ve ekonomik hedeflerini, k resel pazarlama politikalarının belirlenmesi ve kullanılması, performans  lme uygulamalarına g re iřletme ekonomik kaynaklarının eksik kullanılması ihracat performansını etkilemektedir. Bu baėlamda ihracat performansı; ihracat yapan iřletmenin yarattıėı ihracat pazarlama politikalarının ve iřletme faaliyetlerindeki firma kaynak kullanım etkinliėi olarak aıklanmaktadır. İhracat performansının; iřletme ve iřletme evresine  zel řartlar altında ihracat iřleminin sonucu olarak, iřletmenin k resel alanda gerekleřtirdiėi satıřların sonucu olarak veya iřletmenin dıř pazardaki ekonomik bařarı seviyesi olarak farklı tanımları bulunmaktadır. İhracat performansı

değerlendirme ölçütlerinin nesnel ve öznel olarak ikiye ayrıldığı görülmektedir. Nesnel kriterler; ihracat satış oranı, ihracat karlılık oranı ve bu oranların değişimleriyle ilgili ölçütlerden meydana gelmektedir. Öznel kriterler; pazardaki genişleme, rekabet stratejileri, ürün farkındalığının artması gibi stratejik ölçütlerin yanı sıra memnuniyet, ürün başarısı gibi davranışsal ölçütleri de kapsamaktadır. İşletmelerin yapısal yetersizlikleri, ihracat ve yerel pazar bilgilerinin aynı finansal tablolarda gösterilmesi nedeniyle oluşan belirsizlikler, işletmelerin paylaştığı ekonomik verilerdeki yetersizlikler ve farklı muhasebat yöntemlerinin kullanılması nesnel ölçütlerin kullanımında olumsuzluklara neden olmaktadır. Bu olumsuzluklar nedeniyle ölçüm için öznel ölçütlerin tercih edildiği görülmektedir (Akay, 2021: 37).

İşletmelerin küresel pazarda faaliyet göstermelerinin en kolay ve hızlı yolu ihracattır. İşletmenin ülke sınırları dâhilinde üretimini yaptığı ürünleri küresel pazarda satmak için yapacağı finans veya yönetim gibi kaynaklara yapılan yatırım maliyetleri daha düşüktür. İhracat; işletmelerin küresel ölçüde tecrübe kazanması, pazara girerken kullanacağı stratejileri belirlemeleri ve bunların yanında pazardaki belirsizliği azaltmaya yönelik bir basamaktır (Salahoğlu, 2019:43). İşletmelerin ihracatla ilgili faaliyetleri küresel olma anlamında faydalı bir araçtır. Çünkü işletmeler ihracat faaliyetleri nedeniyle ticari yetenekleri, uluslararası pazarda yer alması ve kurumsallık yeteneklerinin artmasına katkı sağlamaktadır. Küresel pazarda gerçekleştirilen satışlar; işletmelerin farklı pazarları tanıyarak kurumsal yetkinliklerini arttırmalarını, zevk ve tercihleri farklı olan tüketiciyle iletişim kurarak ticari yetkinliklerini arttırmalarını, küresel pazarda var olabilmek için kendi yetenek ve iç kaynaklarını geliştirmelerine imkân sunmaktadır. Bu doğrultuda ihracat, daha küresel olma adına en uygun kaynak olarak tanımlanmaktadır. Küresel ölçekte büyümek işletmeler için bir süreçtir ve adım adım yürütülmesi gerekmektedir. İşletmelerde süreç içerisindeki artan tecrübe gerek yurt içinde gerekse yurt dışında bulunan fırsatlarla ilgili daha fazla bilgi akışı sağlar. Buna paralel olarak zamanla işletmelerin küresel pazara dâhil olma sayısı da artmaktadır. Küresel pazarda daha fazla yer almada oldukça etkili bir yol olan ihracat stratejisinin daha etkin olması için elde edilen bilgiyi uygulama adımı teknik anlamda uzmanlaşma ve örgütsel yeterlilik zaman alan bir süreçtir (Majocchi, Bacchiocchi, Mayrhofer, 2005: 720).

Tarihsel perspektif açısından uluslararası ticaret teorileri ilk olarak hammadde ve emek etkenleri üzerine yoğunlaşmış olsa da günümüzde sermaye ve teknoloji etkeninin büyük bir öneme sahip olduğu görülmektedir. Ekonomi teorileri klasik ve

neo-klasik dönemlerde uluslararası ticaret ağırlıklı olarak; hammadde, tarım ve işçilik yoğun sanayi üretimi kavramları ile açıklanmaktadır. Ancak günümüz küresel ekonomi teorileri malların farklılaştırılması yani yoğun sermaye ve teknoloji içeren endüstriyel ürünlerin ticareti üzerine yoğunlaşmaktadır. Bu açıdan bakıldığında; uluslararası ticarete teknolojik gelişmenin ne kadar önemli olduğu ve küresel ticaret hacmini ne kadar arttırdığı görülmektedir. Ülkeler tarafından geliştirilen teknolojilerle üretilen ürünler aynı zamanda üretim yöntemlerini de geliştirmektedir. Gelişen teknoloji böylece ülkelerin küresel ekonomi içerisinde rekabet avantajı ve üstünlük kazanmasını sağlamaktadır. Küresel ekonomide sağlanan avantaj ve üstünlük aynı zamanda ülkelerin ekonomik büyümesini de olumlu yönde ilerletmektedir. Küresel ekonomilerde ülkelerin uluslararası ticaret hacimlerini arttırmalarının birinci yolu; teknolojik olarak altyapı sağlanarak yeni ürünlerin ortaya çıkarılmasıdır. Bu hedefe yönelik olarak ülkeler devamlı olarak teknolojik ürün çeşitliliğini arttırarak dış ticaret hacimlerini de arttırmayı hedeflemektedir. İkinci durumda ise; ülkeler uluslararası ticarete konu olan malların üretiminde verimlilik artışı yakalamayı amaçlamaktadır. Ülkelerin ortaya koyacakları teknolojik yenilikler sonucu üretim süreçlerinde yaşanan gelişmeyle; üretim maliyetlerinin düşürülüp verimliliklerinin artırılması hedeflenmektedir (Şeker, 2018: 2).

Ülke ekonomilerinde görülen ekonomik büyüme oranlarının incelenmesinde tek bir etkenin değerlendirilmesi, ülke ekonomik performansını ölçmede yetersizdir. Yüksek büyüme oranlarının yakalanmasında yenilikçi ve teknolojik ürünlerin sürece olan katkısı oldukça büyüktür. Teknoloji ve katma değeri yüksek ürünlerin ülkelerin ekonomik büyümelerine olan etkisi incelendiğinde; gelişmiş ülkelerin ihracat kalemleri içerisinde yüksek teknoloji ürünlerinin önemli bir katkı sağladığı görülmektedir. Katma değeri yüksek ve ileri teknoloji ürünleri; tıbbi ürünler, havacılık, bilimsel malzemeler ve yüksek teknoloji içeren ürünler olarak sınıflandırılmaktadır. Gelişmiş ülkelerin sahip olduğu ekonomik ivmenin nedenleri uzun dönemde incelendiğinde, teknoloji yoğun ilerlemeler ve bu ilerlemeye temel olan ar-ge faaliyetleri göze çarpmaktadır. Teknolojik altyapı anlamında yetkinliklerini arttıran firmalar rekabet gücünü de arttırarak yüksek karlılık sağlamaktadır. Yüksek teknolojiye sahip ürünler üretmek üretimde etkinlik ve verimli kaynak kullanımı sağlarken aynı zamanda ekonomik büyümenin de artmasına katkı sunmaktadır. Hem gelişmiş hem de gelişmekte olan ülkeler için

yüksek teknolojinin ihraç edilmesi, katma değerin yüksek olması dolayısıyla ekonomik büyümede belirleyici bir unsur olmaktadır (Özkan ve Yılmaz, 2017: 2).


İKİNCİ BÖLÜM

VERİ AMBARI VE VERİ TAHMİN YÖNTEMLERİ

2.1.VERİ AMBARI

Veri ambarı, 1990 yılında temelleri atılan bilgi sistemleri mimarisinin merkezidir. Veri ambarı geçmiş verilerden oluşan ve analiz yapmak için bütünleşmiş güvenilir bir platform sağlayarak bilgi işlemeyi desteklemektedir. Aynı zamanda ayırık uygulamaların yer aldığı sistemlerde bütünleşik işlem yapma imkânı sunmaktadır. Evrimsel aşamalar sonucu elde edilen veri ambarı; uzun bir tarihsel zaman perspektifi üzerinden bilgi edinmek amaçlı, analitik işlemler yapabilmek için gereken verileri düzenler ve muhafaza eder. Bir veri ambarı oluşumundan bahsedebilmek için verilerin; spesifik bir konuyla ilgili, bütünleşik, zaman değişkeni içeren ve tutarlı yapıda olması gerekmektedir. Veri ambarına dâhil olan veriler hemen her durumda operasyonel ortamdan gelmektedir. Veri ambarı daima operasyonel ortamdaki uygulamaların verilerinden dönüştürülen fiziksel olarak ayrı bir veri deposudur (Inmon, 2002: 1).

Şekil 1: Veri Ambarı Nedir?



Kaynak: Inmon, 1995: 1.

Veri ambarları, ilişkisiz veri kaynaklarından alınan verilerin birleştirilerek bu verilerin karar destek uygulamalarında kullanılabilmesi için çok boyutlu olarak saklanmasıdır. Geleneksel veri tabanı sistemi kullanıcıların günlük hareketlerine bağlı işlemleri desteklemek için tasarlanmıştır ve işletimsel/hareketsel (operational/transactional) olarak isimlendirilmektedir. İşletimsel bir sistem hareket

veya işlem odaklı iken veri ambarı konu odaklıdır. Veri ambarı sorgulama ve veri analizi için oluşturulan bir veri tabanı yapısıdır. Genel olarak tarih bilgisi içeren bir hareket verisi ve diğer dış kaynaklardan elde edilen verileri de içerebilir (Gülçe, 2010: 4).

Veri ambarı; daha hızlı ve daha iyi karar alabilmek için analistin bilgisini desteklemeye odaklanan bir karar destek ağıdır. Veri ambarı kalıcı, belirli bir konuyla ilgili ve birbiriyle entegre verilerin derlenmiş olduğu bir havuz olarak tanımlanabilir. Bir veri ambarının oluşturulma amaçları içerisinde (Gupta ve Jolly, 2021: 1);

- Çeşitli heterojen kaynaklardan bilgi toplanabilmesi,
- Heterojen kaynaklardan toplanan verilerdeki kusurları tespit etmek ve düzenlemek için kullanılabilmesi,
- Heterojen kaynaklardan alınan ve farklı biçimlerde karakterize edilen verilerin belirli bir formatta bütünleştirilebilmesi,
- Verilerin düzenlenmesi, ilişkilendirilmesi, değerlendirilmesi, gerekiyorsa bölümlendirilmesi veya bütünleştirilmesi için gerekli kontrollerin geliştirilmesi gibi nedenler sayılabilmektedir.

Sorgulama ve analiz yapabilmek için mevcut bütünleşmiş bilgilerin depolandığı veri ambarı; birden fazla, muhtemelen çok büyük, farklı kaynaklarda ve heterojen yapıdaki veritabanları ve diğer bilgi kaynaklarından gelen verilerin entegrasyonuna yönelik bir yaklaşımdır. Veri ambarında saklanan veriler, kuruluşlar tarafından karar destek sistemlerinde kullanılabilir. Toplu olarak veri sorgulamaları yapıldığı için veri ambarının yerel bilgisayarda bulunması gerekmektedir. Bir veri ambarı farklı kaynaklardan gelen verileri içeren bir depo olarak görülebilir (Theodoratos ve Sellis, 1997: 1-2). Bir veri ambarında karar destek sistemi veya sorgulamaları verimli bir biçimde kullanabilmek amacıyla, bir veya daha fazla veri kaynağından alınan verileri somut olarak depolar. Veri ambarına dâhil edilecek verilerin niteliği oldukça önemlidir (Gupta, 1996). Bir veri ambarının karakteristik özellikleri arasında (Inmon, 2002);

- Konu Odaklı Olması: Bir veri ambarının ilk özelliği işletmenin ana konularına yönelik olmasıdır. Veri ambarı dünyası; müşteri, satıcı, ürün ve faaliyet gibi ana konular etrafında organize edilmiştir. Veri ambarına dâhil edilecek verilerin seçim nitelikleri ambarda yer alacak

verilerin tasarım ve uygulamalarını etkilemektedir. Veri analizi hem veritabanı tasarımı hem de süreç tasarımıyla bağlantılıdır. Veri ambarı yalnızca veri modelleme ve veritabanı tasarımına odaklanmaktadır. Süreç/fonksiyon uygulama yönelimi ile konu yönelimi arasındaki farklılıklar; ayrıntılı düzeyde veri içeriğinde de farklılıkları ortaya çıkarmaktadır. Veri ambarı içerisinde yer alan veriler, veri analizi yapacak kişiye herhangi bir faydası dokunabilecek işlevsel verileri içerir. Uygulamaya yönelik operasyonel verilerin veri ambarında yer alan verilerden farklı olmasının diğer bir önemli nedeni de, veriler arasındaki ilişkilerdir. Operasyonel veri devam etmekte olan bir iş kuralına göre; iki veya daha fazla tablo arasındaki devam etmekte olan bir ilişkiyi sürdürmektedir. Veri ambarı verileri ise belirli bir zaman aralığını kapsayan ve çoklu ilişkili verileri içerir.


- **Bütünleşik Olması:** Veri ambarı ortamının en önemli özelliği barındırdığı verilerin bütünleşik olmasıdır. Veri ambarının bütünleşik olması; adlandırma kurallarına, değişken ölçümlerindeki tutarlılığa, değişkenlerin tutarlı bir biçimde kodlanmasına ve verilerin tutarlı fiziksel özellikleri gibi pek çok farklı biçimde ortaya çıkmaktadır. Geçmiş yıllar boyunca tasarımcılar bir uygulamanın tasarımıyla ilgili kararları bireysel olarak vererek; kodlama farklılıkları, uygulamanın temel yapı ve fiziksel özellikleri üzerinde tutarsız uygulamalar oluşturulmasına neden olmuşlardır. Veri ambarı tasarım standartları bu tutarsızlıkların da önüne geçilmesine imkân sunmaktadır. Uygulamadan gelen verinin ölçüm birimi ne olursa olsun veri ambarında verilerin aynı ölçüm birimiyle saklanması, verilerin bütünleşik olmasına ve uygulama farklılıklarının ortadan kaldırılmasına yardımcı olmaktadır.
- **Zaman Değişkeni İçeriyor Olması:** Operasyonel ortamda bulunan veriler, veriye erişim anından itibaren doğrudur ancak, veri ambarındaki veriler belirli bir zaman itibarıyla doğrudur. Yani operasyonel ortamda yer alan veri birimine erişildiğinde, erişim anından itibaren doğru değerleri yansıtmaları beklenmektedir. Ancak veri ambarındaki veriler, ambarda bulundukları zaman değişkenine ait doğru bilgiyi göstermektedir. Veri ambarında yer alan verilerin zaman

farklılığı oluşmasının ilk nedeni; verilerin 5-10 yıl gibi çok uzun zaman aralığını temsil ediyor olmasıdır. İkinci nedeni; veri ambarındaki yer alan gün, ay, yıl gibi bir zaman ögesi içeren anahtar yapının zımnen tekrarlanmasıdır. Zaman farklılığı oluşmasının diğer bir yolu ise; verilerin bir kez doğru bir şekilde veri ambarına kaydedildikten sonra güncellenmemesi gerekliliğidir. Veri ambarında yer alan veriler, ambara eklenirken doğruluğundan emin olarak eklenmeli ve daha sonra değiştirilmemelidir. Bazı durumlarda veri ambarında yer alan verilerin değiştirilmesi etik dışı, hatta yasa dışı olabilmektedir.

- Verilerin Kalıcı Olması: Veri ambarındaki veriler kalıcı olma özelliğine sahiptir. Uygulama ortamında yer alan verilere ekleme ve güncelleme gibi değişiklikler işletim ortamında düzenli bir şekilde gerçekleştirilmektedir. Ancak veri ambarında yer alan verilerin manipülasyonu çok daha basittir. Bu nedenle veri ambarı içerisindeki kayıtlar üzerinde gerçekleştirilebilen yalnızca iki tür işlem bulunmaktadır. Bunlar; ilk yükleme ve verilere erişim işlemleridir. Operasyonel işleme ile veri ambarındaki veri işleme süreçleri arasında veri güncelleme farklılığın meydana getirdiği çok güçlü sonuçlar bulunmaktadır. Tasarım aşamasında veri güncellemesi yapılmadığından veri ambarında güncelleme anomalisine karşı dikkatli olunması gerekmektedir. Operasyonel ortamda sürekli senkronize biçimde gerçekleşen veri güncellemesi veri ambarı için oldukça karmaşıktır.

Yüklenen verinin yalnızca okunur ve değişken olmayan bir yapıda olması veri ambarının en belirgin özelliğidir. Genellikle gerçek zamanlı olan işletimsel verinin aksine veri ambarı tarihsel verileri içermektedir. Veri ambarı içerisindeki tarihsel veri geleceğe yönelik tahminler yapabilmek, raporlama ve analiz işlemleri için kullanılmaktadır. Bu nedenle veri ambarı tasarlanırken gerçekleştirilecek uygulamaya uygun biçimde tasarlanmalıdır (Gülçe, 2010: 5).

Şekil 2: Veri Ambarı Girdi-Çıktı Şeması



Kaynak: Cabral, 2021: 6.

Son yıllarda pek çok firma veri ambarını karar destek sistemlerinin altyapıları haline getirmiştir. Veri havuzları işletmelerin karar destek mekanizmalarının doğru çalışmasına engel olan yanlış veya bulanık veri, entegrasyon eksiklikleri veya istenilen zamanda veriye erişememek gibi sorunlara etkili bir çözüm sağlamaktadır. Veriler; sorgulama ve raporlama, karar destek sistemi, yönetici bilgi sistemi, analitik veri işleme veya veri madenciliği gibi hangi alanda kullanılıyor olursa olsun, veri ambarı tüm bu uygulamalara veri kaynağı sağlamaktadır. Veri ambarı ayrıca müşteri ilişkileri yönetimi (CRM), iş performansı yönetimi (BPM) veya tedarik zinciri yönetimi gibi mevcut stratejik uygulamalara da veri desteği sağlamaktadır. Pek çok farklı kaynağa veri desteği sağlayan veri ambarında doğru verilerin temin edilmesi veri ambarı mimarisinin de iyi tasarlanmış olması gerekmektedir. Kötü tasarlanmış bir veri ambarı mimarisi; ölçeklenebilirlik eksikliği veya performans sorunlarına yol açabilmektedir. Veri ambarında yer alan veriler kaynaklarından alınarak gerekli dönüşümler yapıldıktan sonra veri depolarına yüklenmektedir. Oluşturulan havuzda yer alan veriler daha sonra uygulama kullanımına sunulmaktadır (Ariyachandra ve Watson, 2010: 201).

Bir veri ambarı; genellikle çevrimiçi analitik işleme yöntemleriyle stratejik karar vermede kullanılan bütünleşik bir veri koleksiyonudur. Temel anlamda; çoklu, heterojen, bağımsız ve dağınık bilgi kaynaklarından çıkarılan bütünleşmiş ve tarih parametresi içeren toplu bilgileri depolayan bir veri tabanıdır (Hüsemann vd. 2000: 1).


Pek çok farklı alanda veri ambarı bilgileri incelenebilmekte ve yönlendirilebilmektedir. Veri ambarında yer alan bilgilerin analiz edilmesiyle; üretim stratejilerini belirlemeye yönelik ürünlerin yeniden düzenlenmesi ve satış karlılığını arttırmak için ürün portföylerinin belirlenmesi, müşteri bilgilerinin analiz edilerek pazar araştırmalarının yapılabilmesi veya müşteri ilişkilerinin yönetilmesinde hayati bir rol oynamaktadır. Bir veri ambarında yer alan veriler üç kategoride değerlendirilebilir (Gupta ve Jolly, 2021):

- **Yapılandırılmış Veriler:** Veri tabanındaki verilerle karşılaştırılabilecek geçmiş tarihli kayıtlardır. Veri tabanındaki veriler satır ve sütunlar şeklinde saklanabilmekte ve basit sorgularla bu verilere erişim sağlanabilmektedir. Verilerin anlaşılabilmesi için belirli satır ve sütundaki değişkenlere basit sorgularla erişilebilmelidir. Veriler genellikle veri tabanında yer aldığı formatla temsil edilmektedir.
- **Yapılandırılmamış Veriler:** Bu tür veriler genel olarak multimedya içeriğine sahiptir. Multimedya farklı görüntü, video ve ses formatlarından oluşmaktadır. Büyük veri, bulut bilişim uygulamasındaki işlemlerin ana kaynağı olabilir.
- **Yarı Yapılandırılmış Veri:** Bu veri türü web uygulamasına bağlantı sağlamaktadır. Her web uygulamasında bir tür veri aktarım mekanizması ve kullanıcı/veri tabanı verisi tutabildiği bir çerçevesi bulunmaktadır. Tüm bu bilgiler istemciden veri tabanına veri aktarımı yapılarak gerçekleştirilmektedir.

2.1.1. Veri Ambarı Katmanları

Geliştirildiği sistem bazında farklılık gösterebilen veri ambarı yapısında kimi sistemlerde tek bir kaynak yer alırken, kimi sistemlerde onlarca kaynak bulunabilmektedir. Kimi veri ambarları tek bir veri pazarı kullanırken, kimileri çok sayıda tablodan meydana gelen veri modeli ile kullanıma hazırlanmaktadır. Bu kullanım farklılıkları nedeniyle veri ambarı şekil 3'te görüldüğü gibi 6 katmanda incelenebilmektedir (Ünal, 2018: 11).

Şekil 3: Veri Ambarı Mimarisi



Kaynak: Dias et. al. 2008: 5 kaynağından alınarak yeniden düzenlenmiştir.

2.1.1.1. Veri Kaynağı Katmanı

Verilerin bilgisayar uygulamalarında saklandığı ve güncellendiği platform veri kaynağıdır. Veri sabit disk veya yüksek miktarda depolama imkânı bulunan uzak sunucularda saklanmaktadır. Veriler ilk akla gelen veri kaynağı olan veri tabanı dışında; dosya, veri sayfası, XML dosyası gibi farklı formatlarda da saklanabilmektedir. Kullanım yeri ve amacına göre farklılıklar gösteren veri kaynakları herhangi bir veri ambarının temel ögesi durumundadır. Farklı veri kaynakları tarafından beslenen veri ambarı; metin dosyası, excel veya ilişkisel veritabanı olarak tanımlanabilmektedir. Bahsedilen veri kaynaklarında; operasyonel satış verileri, kullanıcı bilgileri, ithalat-ihracat verileri gibi çeşitli veri türleri olabilmektedir (Ünal, 2018: 11).

2.1.1.2. Veri Aktarma Katmanı

Verilerin bulundukları kaynaktan çıkarılarak depolama alanında saklandığı katman, veri aktarım katmanı olarak tanımlanmaktadır. Depo alanındaki veriler daha sonra gerekli dönüşümler yapılarak veri pazarına ya da bir tablo haline getirilerek veri ambarına yüklenmektedir. Dönüştürme aşamasında veri temizlenmekte ve veriye anlam kazandırılmaktadır. Veri ambarı tasarlanırken en çok zaman ayrılan işlem adımdır. Farklı veri kaynaklarını tek çatı altında toplayarak ve yeni kaynaklar

ekleyerek veri aktarım aşamasının kolaylıkla devam etmesini sağlayan bir katmandır (Ünal, 2018:11).

2.1.1.3. Depolama Katmanı

Farklı kaynaklardan toparlanan verilerin veri ambarına aktarılmadan önce tutulduğu katmandır. Verilerin temizlenmesi, değiştirilmesi ve birleştirilmesi gibi işlemler bu katmanda gerçekleştirilmektedir. Veri projelerinin daha akıcı ve süreklilik sağlanacak biçimde gerçekleştirilebildiği platformdur. Veri ambarında yer alacak bilgileri içeren tabloların yer aldığı katmandır (Menolli ve Dias, 2006: 1).

2.1.1.4. Veri Katmanı

Tablo ve veri pazarlarında yer alan verilerin belirli bir sistematik ile ilişkilendirilerek veri modelinin geliştirildiği katmandır. Birden fazla boyut kullanılmasının; ilişkilendirilen veri tabanı platformunda çok boyutlu analiz yapılabilmesi ve sorgulama süreç performansını arttırmasıdır (Song vd. 2001:).

Veri ambarı katmanının daha detaylı kavranabilmesi için açıklanması gereken tanımlar (Ünal, 2018: 13);

- **Olgu Tablosu:** Farklı boyutlarda saklanan verilerin yer aldığı bu tablodan verilerdeki tarihsel değişimlerde görülebilmektedir. Örneğin, bir ürün/hizmete ait zaman, kimin tarafından yapıldığı ve müşteri bilgileri gibi verilerin raporlanabilmesi için olgu tablosunda yer alıyor olması gerekmektedir.
- **Boyut Tablosu:** Olgu tablosuna eklenen verilerin; isimlendirme ve tanımlamalarının ayrıntılı biçimde saklandığı tablodur. Olgu tablosundaki birincil anahtar verisi üzerinden bu detaylara ulaşılabilir.
- **Ölçü:** Olgu tablosunda sayısal olarak tutulan veriler ölçü olarak tanımlanmaktadır. Ortalama, min/max değer vb. gereken matematiksel hesaplamalar ölçü değeri kullanılarak gerçekleştirilmektedir.

2.1.1.5. Analiz Katmanı

Bu katmanda bilgiler kullanıcıya sunulmaktadır. Analitik yöntemlerle veriye erişen son kullanıcı veriler üzerinde gerekli analizleri gerçekleştirebilir. Çıkarım yapılan yeni verilerden yeni kural, öngörü veya algoritmalar oluşturulabilmektedir. Analitik işleme, tablo/grafik hazırlama, raporlama ve veri madenciliği yöntemleri en sık tercih edilen araçlardandır. Ayrıca özet haline getirilmiş tablolar veya kullanıcı bilgilendirmeleri için yine analiz katmanı kullanılmaktadır. Ulaşılmak istenen her sonuç için ayrı bir uygulama geliştirilmesi gereklidir. Analiz aşamasında veriler; çevrimiçi analitik işleme (OLAP) veya raporlama sistemleri kullanılarak işlenebilmektedir. Çevrimiçi analitik işlemenin; verilerin birden fazla boyutta incelenebilmesi, her veri düzeyinde gerçekleştirilen sorguların eşit sürede sonuçlandırılabilmesi, raporlama ortamındaki esneklik, herhangi bir sınırlama olmaksızın veri gruplandırması yapılabilmesi gibi avantajları bulunmaktadır (Ünal, 2018: 15).

Raporlama sistemlerinde ise kullanıcılara istedikleri zaman ve kriterlerde veri raporlama imkânı vermektedir. İhtiyaçlara anlık cevap verebilme ve kullanıcılara esneklik sunan bu raporlama araçlarında arka planda sistem yöneticisinin oluşturduğu veri modelleri yer almaktadır. Veri madenciliği uygulamalarına göre daha basit yapılabilen raporlama araçlarında ihtiyaca yönelik hazırlanan sorgular, farklı algoritmalar ve ilişkisel tablolar bulunmaktadır (Menolli ve Dias, 2006).

2.1.1.6. Meta Veri Katmanı

Verilerin tutulduğu katmandır. Diğer bir deyişle; verinin beslendiği kaynağı, uygulanan dönüşüm işlemlerini ve görselleştirildiği rapor bilgisini içerir. İyi bir meta veri bilgisinden yola çıkarak hem hedeflenen bilgiye hızlı ve kolayca erişilebilmesi açısından, hem de veri ambarının verimliliği ve etkinliği açısından oldukça önemli bir katmandır (Ünal, 2018: 18). Genel tanımıyla meta veri; veriyle ilgili geliştirilen yazılımlar ve verinin ortaya çıkmasından itibaren bilgi işleme sürecine dâhil olmaktadır. Veri ambarının en etkin biçimde kullanılmasına imkân sunan meta verinin veri ambarı mimarisindeki önemi giderek artmıştır. Veri ambarı ortamında; veri ambarındaki tüm parçaları birleştiren bilgi sağlaması, yazılım geliştirici ve analistlere teknik bilgi sağlaması, son kullanıcı için veri ambarındaki bilgiye kolay erişim sağlaması meta verinin önemini göstermektedir (Kutlu, 2016: 34).

Veri ambarının içeriğinin oluşturulmasıyla ilgili bir kaynak olarak düşünülebilecek meta veri; verinin tanımlamasını, tipini, kaynağını ve nasıl hesaplandığı bilgilerini bulundurmaktadır. Veri ambarında yer alan verinin yanı sıra ambarın nasıl işlediğini de tarif eden bir katalog görevi gören meta verinin geliştirilmesi veri ambarını diğer yazılım geliştirme süreçlerinden farklı kılan bir bileşendir (Ponniyah, 2001: 281).

2.1.2. Veri Ambarında Yer Alan Verinin Kalitesi

Günümüzde modern işletmeler birden fazla veri kaynağını entegre eden veri ambarlarına karar alma aşamasında giderek daha fazla güvenmektedirler (Jannot vd. 2017; Sebaa vd., 2018; Xu vd, 2019). Ancak veri ambarına dayalı kararların etkisinin de kaliteli olması veri ambarında yer alan veri içeriklerinin kalitesine bağlıdır. Veri kaynaklarında yer alan veri kalitesi öngörülemez risklere neden olabilmektedir. Düşük veri kalitesi veri ambarının kalitesi üzerinde de büyük bir engel teşkil etmektedir. Veri ambarına dâhil edilecek veri kaynaklarının kontrol edilmesi, veri ambarının kalitesini iyileştirmek ve maliyetleri düşürerek verimlilik artışı sağlamak için oldukça önemlidir. Veri kalitesi; veri kaydı gerçekleştiren kaynak ile gerçek dünya varlığının nitelikleri arasındaki fark olarak ifade edilmektedir. Lu ve arkadaşları (2017) veri kalitesini verilerin doğruluğu olarak tanımlamışlardır. Wang ve Strong (1996) ise veri kalitesini incelemek için doğru veri olması, verilerin ilişkili olması, verilerin neyi temsil ettiği ve erişilebilirliği şeklinde dört kategori tanımlamışlardır. Garcia-Bernardo ve Takes (2018) ise veri kalitesini tanımlamak için eksiksiz ve doğruluk olmak üzere iki kriter tanımlamışlardır. Wahyudi vd. (2018) veri kalitesinin en iyi tanımının kullanıma uygunluk olduğunu ve nitelik seçiminin kullanım alanına göre seçilmesi gerektiğini dönüşmektedirler (Liu vd., 2019: 375).

Veri ambarı, işletmenin tüm karar verme seviyeleri için veri desteği sağlayan stratejik bir birimdir. Veri ambarı veri depolamak için genellikle ilişkisel veri tabanını kullanır. İlişkisel veri tabanı içerisinde yer alan veri kalitesi ise hatalı veri, eksik veri ve yanlış ilişkilendirilen verilerle ölçülmektedir (Dey ve Kumar, 2013).

Veri kalitesi; verideki tutarsızlık veya yazım hataları, gerçek veri ile veri ambarında saklanan değerler arasındaki uyumsuzluk gibi çeşitli ölçütler dikkate

alınarak bir veri kümesiyle gerçek veri arasındaki uyum düzeyi olarak tanımlanmaktadır (Cabral, 2021: 11).

Veri kalitesinde yaşanabilecek sorunların çözümü için verilerin tanımlanması, ölçümü, analiz ve iyileştirmesini içeren dört adımdan oluşan toplam veri kalitesi yönetimi yaklaşımı önerilmektedir. Veri kalitesi yönetimi stratejisi iki kategoriye ayrılmaktadır. Bu kategorilerin ilki teknik odaklıdır ve hatalı kayıtların eksiklerini tamamlamaya yönelik en uygun yöntemleri tasarlamaya odaklanmaktadır. Örneğin varlık çözümleme teknolojisi ile aynı veriyi farklı veri kaynaklarından doğrulayarak veri tutarlılığı artırılmaktadır. İkinci kategori ise; zayıf veri kalitesinin maliyetiyle veriyi iyileştirme maliyeti arasında bir denge sağlamak için veri kalitesini kontrol ederken yönetsel metotların kullanılmasına odaklanmaktadır (Liu vd. 2019: 377).

Bir organizasyondaki herkesin korumak ve geliştirmekte sorumlu olduğu önemli bir varlık olan bilginin kalitesiyle ilgili kriterler (Rifaie vd. 2008: 63);

- Veri doğruluğu: Veri girişi, güncellemesi ve silinmesinden sorumlu olan çalışanlar aynı zamanda veri kalitesi ve doğruluğundan da sorumludurlar.
- Veri tutarlılık ve bütünlüğü: Bir organizasyonda depolanan verilerin hangi birimde olduğuna bakılmaksızın, organizasyon genelinde tutarlılığa sahip olmalıdır. Veriler kurumsal çapta bütünlüğe sahip olmalıdır.
- Veri belirleme: Veriler olabildiğince menşei olan kaynağa yakın ve elektronik ortamda belirlenecektir.
- Veri değişimi: Veri ambarına dâhil edilmek için bir kez belirlenen veriler elle müdahale ve tekrarlı veriden kaçınabilmek için elektronik cihaz yardımıyla depolanacaktır.

Gelişmiş veri kalitesi için bir organizasyonun yapması gerekenler (Rifaie vd. 2008: 63):

- Verilerin diğer kullanıcılar ve bir bütün olarak organizasyon için olan önemi göz önünde bulundurulmalıdır.
- Bilgiyi tedarik eden bireylerin (örneğin müşteri) bilgiyi doğrulaması sağlanmalıdır.
- Veri kalitesi ölçülmeli ve kalitenin iyileştirilmesi için programlar yapılmalıdır.

- Bilgi sistemlerinden gelen verilerin amaçlandıkları şekilde kullanılmaları gerekmektedir.
- Veri kalitesinin izlenmesi ve iyileştirilmesi için veri yönetimi işlevi geliştirilmelidir.

Verinin daha kaliteli bir forma sokulmasının sağladığı destek ile verilerin doğruluğu, eksiksizliği ve güncelliği arttırılabilmektedir. Geliştirilmiş veri kalitesi ise geleceğe yönelik karar alma adımı için oldukça büyük bir öneme sahiptir. Sağlam bir veri yönetimi; yeni uygulamalarda devam eden dönüşümleri basitleştirmek, kritik öneme sahip eski uygulamaların ömrünü uzatabilmek ve etkili iş ortaklıkları ve paylaşılan hizmet desteğinin geliştirilmesi gibi önemli faydalar sağlayabilmektedir (Rifaie vd. 2008: 63).

Verilerin varlığı tek başına bütün veri yönetimi işlev ve kararlarının alınmasına imkân sağlamaz. Geniş bir ifadeyle veri kalitesine kapsamlı, tutarlı ve anlaşılır veriler üzerinden ulaşılabilir. Kalite kriterlerini sağlayan verilerin yüksek kaliteli veri olduğu söylenebilmektedir. Verinin kalite seviyesi; doğruluk, güvenilirlik, önem, tutarlılık, kesinlik, zamanlılık, uygunluk, anlaşılabilirlik, bilginin özünü içermek ve kullanışlılık nitelikleriyle belirlenmektedir. Manjunath, Ravindra ve Ravikumar(2010)' a göre veri kalitesinin özellik ve ölçüleri;

- Tanıma Uygunluk: Seçilen veri oldukça önemlidir bu nedenle veri tanımları gerçekte temsil ettiği verinin tüm ayrıntı ve anlamını içermelidir.
- Değerlerin Tamlığı: Veri alanları için gerekli tüm değerlere sahip olma özelliğidir.
- Veri Geçerliliği: Veri değerinin etki alanı ve iş kurallarına uygun olma derecesinin ölçüsüdür.
- Kaynağın Doğruluğu: Verilerin orijinal kaynağındaki haliyle ne derece uyumlu olduğudur.
- Kesinlik: Veriyi belirten alan değeri doğru hassasiyette olmalıdır.
- Tekrarlamama: Veri ambarına eklemek üzere seçilen veri ile gerçek veri birebir ilişkili olmalıdır.
- Çıkarsama Bütünlüğü: Yeni veri elde etmek için iki veya daha fazla veri parçasının doğru biçimde birleştirilmesidir.
- Erişilebilirlik: İstenildiğinde veriye erişilebilir olmalıdır.


- Zamanlılık: Spesifik bir sürecin desteklenmesine yönelik verinin gerekli zaman çizgisi üzerinde kullanılabilir olmasıdır.

Veri ambarı için birden fazla kaynaktan veri birleştirme işlemi genellikle dikkat edilmesi gereken pek çok farklı detay içermektedir.

Veri kalitesi çözümünün temel amacı, bir veya daha fazla veri kaynağından gelen verilerin bir araya getirilmesidir. Ancak verilerin bir araya getirilmesi genellikle boş veya eksik bilgiler gibi nedenlerle veri kalitesinde sorunlara yol açmaktadır. Şekil 4'te veri kalitesinin sağlanması süreci gösterilmektedir (Manjunath, Ravindra ve Ravikumar, 2010: 479). Veri kalitesinin yükseltilmesi için izlenecek adımlar (<https://www.yumpu.com/en/document/view/41029734/six-steps-to-managing-data-quality-with-sql-server-integration-> Erişim: 25.10.2021);

- Profil Oluşturma: Veri bütünleştirme adımıdaki ilk savunma hattıdır. Verilerin profilini çıkarma, mevcut veri kaynaklarının kalite standartlarını karşılayıp karşılamayacağını incelemesine yardımcı olmaktadır. Veri profilinin doğru şekilde çıkarılması veri ambarı oluştururken ilgilenilmesi gereken ilk adımdır. Bu şekilde veri ambarı oluşturulurken hemen çözülmesi gereken sorunların belirlenerek, dâhil edilmeyecek veri kaynaklarının belirlenerek gereksiz işlemeden kaçınılması zamandan tasarruf sağlamaktadır. Veri profili oluşturma; referans bütünlüğü veya kalite kontrolleri yapılmamış ham veri kaynaklarıyla çalışılırken daha da kritik bir öneme sahip olacaktır.
- Temizleme: Profil oluşturma işleminin başarıyla tamamlandığı bir veri kümesine tüm kuralların başarıyla uygulandığından emin olmak için yine de veri temizleme ve tekilleştirme işlemleri uygulanmaktadır. Başarılı bir veri temizliği büyük veri kümelerindeki karmaşık kalite sorunlarını ele alabilen esnek ve verimli tekniklerin kullanılmasını gerektirmektedir.
- Standartlaştırma: Bu teknik tutarlı bir veri kümesi oluşturmak için verileri ortak biçimde ayrıştırarak yeniden yapılandırmaktadır. Bu aşamada; tablo, satır, sütun gibi çeşitli veri kümelerinde veri kalıplarını tanımlamak, düzeltmek ve standart hale getirmek için tasarlanmıştır.

Şekil 4: Veri Ambarında Veri Kalitesi Süreci



Kaynak: Manjunath vd, 2010: 479 kaynağından alınarak yeniden düzenlenmiştir.

- Eşleştirme: Veri eşleştirme adımı veri kayıtlarını tanımlanabilir gruplar halinde birleştirerek ilgili kayıtları veri kümesi içerisinde veya arasında birleştirir.
- Zenginleştirme: Veri zenginleştirme adımı coğrafi kodlama, demografik veri, tam isim ayrıştırma, cinsiyet belirleme, telefon veya e-posta doğrulama dâhil olmak üzere diğer kaynaklardan ek veri parçaları eklenerek müşteri verilerinin değeri artırılmaktadır. Veri zenginleştirme süreci; satın alma davranışları veya sadakat potansiyelini ortaya çıkardığı için müşteri verilerinin daha iyi anlaşılmasına imkân sunmaktadır.
- İzleme: Gerçek zamanlı bir izleme aşaması olan bu adımda verilerin daha önceden belirlenen sınırları aştığını tespit etmek için otomatik süreçler devreye girmektedir. Veri izleme, kuruluşların problemleri veri kalitesi düşmeden hemen tanıyarak düzeltmesine yardımcı olmak için tasarlanmıştır. Bu yaklaşım aynı zamanda işletmelerde veri yönetişimi ve uyumluluk önlemlerini uygulama yetkisi vermektedir.

2.2. VERİ TAHMİN YÖNTEMLERİ

Günümüzde veri tahmini için pek çok yeni yöntem uygulanabilmektedir. İstatistiksel analizler piyasa istikametini belirlerken, yatırım araçlarının gelecekteki değerlerini tahmin etmekte de kullanılmaktadır. Küresel ekonomilerde ülkeler arasındaki mesafeler kısalırken rekabet, üretim ve tüketim miktarları oldukça büyük boyutlara gelmiş aynı zamanda riskler de benzer oranlarda artmıştır. Bu nedenle artan risklerinde minimize edilmesi gerekmektedir. Veri tahmininde tek bir yöntem bulunmamakla birlikte genel anlamda bir tahmin; tahmin edilen değişken, tercih edilen teknik, tahminleme işlemini yapacak kişinin uzmanlık düzeyi, gereken zaman ve kaynağın bir araya getirilmesi, elde edilen sonucun hassasiyet düzeyidir. Tahmin edilen verinin maliyeti ayrıntıya inildikçe artmaktadır (Yıldız, 2006:18).

Yatırım projelerinde stratejik kararların verilebilmesi, uygulanan pazarlama stratejilerinin analiz edilmesi, ölçülmesi ve yenilenmesi, yerin ürün ve pazarların belirlenerek geliştirilmesi, firma yönetimi ve karar verme aşamalarında tahmin yöntemleri oldukça önemli araçlardır (Muhlemann vd. 1994; 311).

Geleceği sıfır hata ile öngörmek olası değildir ve tahmin yönetiminde sınırlamalar bulunmaktadır. Tahmin yaparken nihai amaç doğruluğu en yüksek değeri daha önceden tahmin ederek hatayı minimuma indirebilmektir. Tahmin hatası nedeniyle katlanması gereken maliyet, hatayı düzeltme seviyesi ve diğer işletmelerin yaptıkları tahminlerdeki hata oranları oldukça önemlidir (Soysal ve Ömürgönülşen, 2010: 128).

Tahmin süreci; satış, planlama, tedarik zinciri gibi iş süreçlerine sahip firmaların tüm işlem adımlarında karar vermeye yardımcı olan önemli bir süreçtir. Ayrıca günümüz küresel ekonomileriyle bağlantılı olarak artan müşteri beklentileri, sınırlı kaynaklara ulaşma ihtiyacı gibi nedenlerle tahminler firmaların rekabet gücü açısından oldukça önemli hale gelmiştir. Etkili talep tahminleri firmanın stok seviyesini düşürürken aynı zamanda müşteri hizmeti kalitesini de arttırmaktadır. Bazı sanayi kollarında tahmin, firma karlılığını etkileyen birçok operasyon ve karar sürecinde girdi işlevi görmektedir (Sohrabpour vd., 2021: 1).

Bir işletme geleceğe yönelik bir tahmin yapmak istediğinde genellikle süreci hızlandırmak adına diğer firmaların kavramlarını, hedeflerini ve ilkelerini tekrarlama eğilimine girmektedir. Pek çok tahmin işlemi nihai ürün için yapıldığından

tekrarlama eğilimi uyaranların farklı olması nedeniyle hatalı ölçümlere neden olabilmektedir (Kerkkanen, Korpela ve Huiskonen, 2009: 43). Tahmin adımı eksik veya hatalı işlem yapılması firmalara ekstra maliyete neden olabilir. Örneğin hatalı talep tahminleri üretimin optimal olmayan seviyelere çıkması dolayısıyla iş yükü dengesizliklerine, yanlış malzeme envanterine yol açmaktadır. Bütün bu riskler felaket dönemlerinde veya istikrarsız piyasa koşullarında daha da kritik bir öneme sahiptir (Sohrabpour vd., 2021: 1).

Temel olarak iki başlıkta incelenebilen tahmin yöntemleri; Kalitatif (Nitel) ve Kantitatif (Nicel) olarak tanımlanmaktadır. Bir araştırma kapsamında bu iki gruptaki yöntemlerin ayrı ayrı veya birlikte kullanılması gereken durumlar olabilir. Örneğin yeni bir ürün piyasaya sürülürken henüz sayısal bir veri bulunmamaktadır o nedenle bu aşamada kalitatif yöntem tercih edilebilir. Satış sürecinin başlamasıyla elde edilen sayısal veriler üzerinde ise kantitatif yöntemler uygulanmaktadır. Çeşitli zaman aralıklarıyla toplanan sayısal veriler genel olarak kantitatif yaklaşımın girdisini oluşturmaktadır. Kantitatif tekniklerin temelinde verilerin iyi bir şekilde analiz edilmesi yatmaktadır. Kalitatif tekniklerde ise bu durumun aksine, konularında uzman kişilerin bilgi ve tecrübelerinden faydalanarak geleceğe yönelik çıkarım yapılması hedeflenmektedir (Eşidir, 2020: 19).

2.2.1. Nitel Tahmin Teknikleri

Analitik yapıda olmayan bilgilerden üretilen tahminler nitel tahmin olarak isimlendirilmektedir. Örneğin yeni bir ürün satışa sunulacak ve geçmişe ait veri bulunmuyorsa daha çok tercih edilmektedir (Eşidir, 2020:21);

- Elde edilen tahminin kişisel bir yargı veya niteleyici bazı verilere dayandırılması,
- Elde edilen tahmin verisinin öznel ve katılımcı deneyimlerinden geliştirilme eğiliminde olması nedeniyle ön yargı içerebilmeleri,
- Kullanılabilecek başka bir yöntem bulunmaması nedeniyle daha önemli hale gelebilmesi,
- Elde edilen tahmin değerinin genellikle tek bir ürün veya ürün aileleri için nadir olarak tüm pazarlar için kullanılabilmesi nitel tahmin yöntemlerinin başlıca özellikleri içerisinde yer almaktadır.

Alan arařtırmalarından elde edilen veriler genellikle nitel analizde kullanılmaktadır. Arařtırmacı alıřmanın yapıldığı ortamda zaman geirme imkânı bulunduğundan alan arařtırmalarında birinci dereceden gözlem yapabilme imkânı bulunmaktadır. Elde edilen nitel bulgular tek tek kullanılabileceğı gibi nicel verilerle birlikte de sunulabilmektedir (Patton, 2014: 4).

2.2.1.1. Ekstrapolasyon

Sıka tercih edilen bir yöntem olan ekstrapolasyon tekniğinde bir olayın öncül bilgilerini elde etmiş olmak gerekmektedir. Bu teknikte ilk adım, tahmin edilecek konuyla ilgili geçmiş verilerin elde edilmesi gerekmektedir. Önceki veriler deęerlendirilerek, geçmiş zaman gelişmeleri doğrultusunda gelecek tahmin edilmeye alışılmaktadır. En az iki tane peş peşe gerekleşen gözlem olmalı ve bu yöntemi uygulayabilmek için daima uygun eğrinin izilmesi gerekmektedir (Karakan ve Ko, 2008:30).

2.2.1.2. Delphi

Delphi yöntemi ile olayların gelecekte gerekleşme zamanlarını öngörmek için kullanılmaktadır. Uzman görüşlerinin veri kaynağı olarak kullanıldığı bu yöntemde, bir durumla ilgili yaşanan gelişmeler incelenmekte ve uzman bakış açısına başvurularak tahmin gerekleştirilmektedir. Delphi yönteminin işleyiři (Martino, 1993: 15-32);

- Alanında uzman kişilerden soru cevap yöntemiyle bilgi toplanır,
- Bu bilgilerle ilgili uzman yorumları dinlenir ve konu hakkındaki fikirleri incelenir,
- Konu uzmanı kişiler farklı uzman fikirlerini dikkate alarak kendi tahminlerini kontrol eder,
- Kontrol edilen yeni yanıtlar üzerinden sorular daha da özelleştirilerek alanında uzman kişilere tekrar gönderilir,
- Elde edilen yeni bilgiler üzerinden uzmanlardan görüşlerini tekrar düzeltmeleri istenir.

Delphi metodu bu şekilde birkaç defa tekrar edilerek süreç sonucunda tek bir tahmin deęeri elde edilir.

2.2.1.3. Pearl Eğrisi

Bu yöntem en temel anlamıyla olgunluk dönemi devam eden bir teknolojinin limite ulaşma aşamasına geldiğini kabul etmektedir. Pearl Eğrisi yönteminde olgunlaşma seviyesine gelen teknolojileri incelerken ulaşılacak araştırma hedefleri belirlemek ve geliştirmeye devam edilip edilmeyeceği gibi kararların alınmasında kullanılmaktadır. Ek olarak Pearl Tekniği ulaşılacak hedefleri aşp aşmayacağı konusunda da bilgi vermektedir. Genel anlamda bir teknolojinin diğeri yerine geçmesinin başarılı olup olmayacağı veya mevcut teknolojik büyümenin ne zaman durgunlaşacağını öngörmek amacıyla tercih edilmektedir. Eğri çizimini gerçekleştirebilmek için yeterli miktarda geçmişe ait bilgi olması ve teknolojinin ulaşabileceği üst limitin biliniyor olması gerekmektedir (Karakan ve Koç, 2008: 31).

2.2.1.4. Trend Analizi

Uzun vadeli tahminler için tercih edilen trend analizinde tahmini yapacak uzmanın ürünün gelecekteki performansını öngörebilecek yeterlilikte olması gerekmektedir ancak ürün/teknolojinin çalışma prensibini bilmesine gerek yoktur. Trend analizindeki kritik nokta geçmiş veriler üzerinden en doğru trend grafiğinin çıkarılabilmesidir. Eğer yeni teknoloji piyasaya çıktığı andan itibaren düzgün bir trend yakalayabilmişse, gelecek dönemlerinin de bu şekilde olacağı tahminlenir. Veri setinde yer alan verilerin gün, hafta, ay veya mevsim gibi belirli bir zaman birimine göre dağılımının gösterildiği zaman serilerinin analiz edilebilmesi değişkenin uzun dönemdeki trendini belirlemede kullanılmaktadır. Dahası sektörel ekonomilerdeki bolluk veya kriz dönemlerini ve değişken üzerindeki aylık/mevsimlik etkilerin ortaya çıkarılmasına imkân sunmaktadır (Çancı vd., 2015: 63).

2.2.2. Nicel Tahmin Teknikleri

Nicel tahmin teknikleri matematiksel modellerin kullanıldığı yöntemlerdir. Nicel tahmin teknikleri matematiksel modelleri kullanması ve tahmin değerlerinin hesaplanarak elde edilmesi nedeniyle daha güvenilirdir ve tahmin yöntemleri içerisindeki yeri oldukça önemlidir (Şahin, 2020: 24).

Nicel tahmin teknikleri geçmiş veriler kullanılarak gelecek değerlerin matematiksel yöntemlerle öngörülmesi olarak tanımlanmaktadır. Bu yöntem

geçmişle ilgili veri varsa ve veriler matematiksel olarak ölçülebiliyorsa kullanılmaktadır. İstatistiksel modelleri temel alan bu yöntemler en genel haliyle nedensel teknikler, zaman serisi tekniği ve simülasyon tekniği olmak üzere üç temel konu başlığı altında incelenmektedir (Eşidir, 2020: 23).

Yapılan analizlerde girdi olarak sayısal verileri kullanan nicel tahmin teknikleri; verilerin geçmiş sayısal değerlerini kullanarak bir şablon oluşturup bu şablona uygun bir matematiksel model kurar ve geleceğe yönelik öngöründe bulunurken modelin tahmin denklemi kullanılarak analiz yapmaktadır. Tahmin işlemi için kullanılan sayısal veriler; mobil işlemciler veya gözlem sonuçlarının saklandığı veritabanları ya da barkod okuyucular gibi kaynaklardan elde edilmektedir. Nedensel yöntemler ve zaman serisi tekniği olarak iki temel gruba ayrılan nicel tahmin yöntemleri içerisinde daha güncel bir metot olan yapay sinir ağları ise, hem nedensel hem de zaman serisine dayalı model kurulmasında başarılı sonuçlar vermektedir (Ahi, 2015: 36).

Bireysel yargılara ihtiyaç duymayan nicel tahmin yöntemleri, sayısal sonuçlar içeren mekanik uygulamalardır. Bu nedenle karmaşık veri manipülasyonu gerektirmektedir. Geçmişe yönelik sayısal veri olduğunda ve geçmiş verilerin bazı yönlerinin gelecekte de devam edeceği varsayımı ile uygulanabilmektedir. Süreklilik varsayımı olarak bilinen bu varsayım bütün nicel tahmin yöntemlerinin öncülüdür (Hanke ve Wichern, 2005: 3-4). Farklı disiplinler ve farklı amaçlar için geliştirilen nicel tahmin teknikleri, birbirlerinden önemli ölçüde farklılıklar gösterebilmektedir. Her tekniğin dikkate alması gereken özellikleri, doğruluk oranları ve farklı maliyetleri bulunmaktadır. Nicel tahmin yöntemleri sezgisel ve istatistik ilkelere dayanan teknik yöntemler arasında sürekliliğe sahiptir. Sezgisel yöntemler basit ve kullanımı kolay olmakla birlikte, her zaman istatistik temeline dayanan teknikler kadar doğru sonuç vermemektedir. Bu nedenle istatistik yöntemlerin kullanımı daha yaygındır. İstatistik yöntemler de ekstrapolasyon içerebilmekte ancak tahmin hatalarını en aza indirmeye çalışan sistematik bir yaklaşımla standart biçimde yapılmaktadır. Nicel tahmin yöntemlerine aşina olmayan kişiler, genellikle her şey sıklıkla değiştiği için geçmişin doğru öngörülemediğini düşünmektedirler. Ancak veri tahmin yöntemlerini kullanma sıklığı arttıkça hiçbir şeyin aynı kalmamasına rağmen bir anlamda tarihi sürecin kendini tekrar ettiği ortaya çıkmaktadır. Doğru yöntemin uygulanması, genellikle tahmin edilecek değişken ile zaman arasındaki

ilişkiyi tanımlayarak gelişmiş bir tahmin elde edilmesini mümkün kılmaktadır (Sevim, 2006: 10).

Nicel tahmin yöntemlerinde açıklayıcı modeller; tahmin edilecek değişkenin bir veya daha fazla bağımsız değişkenle açıklayıcı bir ilişki sergilediğini varsayar. Açıklayıcı modeller; ulusal ekonomi bir işletmenin pazarı veya hanesi gibi birçok sisteme uygulanabilmektedir. Açıklayıcı modelin amacı, ilişkinin biçimini keşfetmek ve onu gelecekteki değerleri veya tahmin değişkenini tahmin etmek için kullanılmaktadır. Açıklayıcı tahmine göre; girdide meydana gelen herhangi bir değişiklik açıklayıcı ilişkinin değişmeyeceğini varsayarak (süreklilik varsayımı) sistemin çıktısını tahmin edilebilir bir biçimde etkileyecektir. Açıklayıcı tahminden farklı olarak zaman serisi tekniğinde ise; sistemi bir bilinmeyen olarak varsayar ve sistem davranışını etkileyen faktörleri keşfetme girişiminde bulunmaz. Bu nedenle gelecek tahmini bir değişkenin geçmiş değer veya hatalarına dayanmaktadır ancak sistemi etkileyecek herhangi bir açıklayıcı değişkene dayandırılmamaktadır. Bu tekniğin amacı tarihsel veri setlerindeki kalıbı keşfederek geleceğe yönelik öngörü sahibi olabilmektir (Sevim, 2006: 10).

Gerek zaman serileri tekniği gerekse açıklayıcı modeller belirli durumlar için bazı avantajlar sunmaktadır. Zaman serisi modelinde genellikle tahmin için kolay kullanılabilen, açıklayıcı modeller ise politika ve karar verme aşamalarında daha başarılı sonuçlar sunmaktadır. Öngörü için gereken veriler hazır olduğunda, bir tahmin ilişkisi ya bir zaman fonksiyonu olarak ya da açıklayıcı değişkenlerin bir fonksiyonu olarak varsayılabilir ve test edilebilir (Makridakis, Wheelwright ve Hyndman, 1998: 9-12).

Yöntemi kullanmanın getireceği toplam maliyet de tahmin yöntemlerinin tercih edilme veya kullanılmasında dikkate alınması gereken bir adımdır. Nitel ve nicel teknikler karşılaştırıldığında fayda/zarar ve kullanım yerleri (Yıldırım, 2019: 14);

- Tahmin üzerinde çalışacak kişinin matematiksel bir yeterliliğe sahip olması nitel yöntemlerde bir gereklilik değildir.
- Trendlerdeki değişime bağlı olarak tahmin yapılmaktadır.
- Alanında uzmanlık seviyesinde bir yeterliliği bulunan kişilerin görüşlerine başvurulur.

- Nitel tahminlerde geçmişe yönelik çok az veya hiç veri olmadan tahmin yapılabilir.
- Tahmin doğruluğunun nasıl arttırılacağına yönelik bir cevap vermek zor olabileceği için doğruluk oranı zamana bağlı olarak değişken olabilir. Zaman ve maliyet açısından nitel yöntemlere göre daha pahalı olabilmektedir.
- İki tekniği aynı anda kullanmak yüksek uzmanlık gerektirebilmektedir. Böyle bir kullanım tercih edileceği durumda öncelikle nitel yöntemin temel fikir ve varsayımlarına hâkim olmak gerekliliği bulunmaktadır.

Hem günümüzde üretilen mal ve hizmetlerdeki çeşitlilik hem de firmaların işleyişleri pek çok farklılık içermektedir. Bu nedenle kullanılacak olan tahmin tekniğinin de bu çeşitliliğe uygun olması gerekmektedir. Bu çeşitliliğe ayrıca tüketici alışkanlıkları da eklenmektedir. Bu nedenle tek bir tahmin yöntemi kullanılması doğruluk açısından bir zorluğa neden olmakta ve piyasanın ihtiyaçları doğrultusunda farklı tahmin tekniklerinin kullanılması adeta bir zorunluluk haline gelmektedir. Eldeki verilerden veriler arası ilişkileri tahmin etmeyi amaçlayan istatistik yöntemlerle oluşturulan modeller, diğerlerine göre hem daha düşük maliyetli hem de daha faydalı olmaktadır. İstatistiksel yaklaşım özellikle dar zaman aralıklarında daha güvenilir olarak bilinmektedir. Ayrıca istatistik modellerin geliştirilmesi kolay ve diğer yöntemlere oranla daha ekonomiktir (Kırbaş, 2018: 25).

Tek ve çok değişkenli analiz teknikleri olarak ikiye ayrılan istatistik analiz yöntemleri kullanılan modelin değişken sayısı açısından farklılık göstermektedirler. Bağımsız değişkenin yalnızca bir oran olarak kullanıldığı tek boyutlu modeller uygulama kolaylığı sağlamakla birlikte; çelişkili sonuçlar ortaya çıkarabilmesi, diğer önemli oranlara yer verilmemesi, modeli tek bir değişken ile elması ve öngörü gücünün daha düşük olması gibi dezavantajlara sahiptir. Tek boyutlu modellerin dezavantajları dolayısıyla öngörü aşamasında çok boyutlu modeller daha çok tercih edilmektedir (Aktaş, Doğanay ve Yıldız, 2003:5).

Yapılan araştırmalar sonucunda sağlıklı sonuçlara ulaşabilmek için araştırmanın tüm boyutlarının incelenmesi gerekmektedir. Bu nedenle araştırmada yer alan tüm değişkenler ve etkileri ayrı ayrı incelenmelidir. Bu nedenle tek değişkenli analiz teknikleri yerine çok değişkenli analiz tekniklerinin kullanımı giderek yaygınlaşmaktadır. Çok değişkenli varyans analizi, regresyon analizi gibi

teknikler sıklıkla kullanılan çok değişkenli istatistiksel analiz yöntemleri olarak karşımıza çıkmaktadır. Psikoloji, sosyoloji veya iktisat gibi alanlarda çok değişkenli analiz teknikleri sıklıkla tercih edilmektedir (Toker, 2013:12).

2.2.2.1. Sebep-Sonuç İlişkisine Dayanan Teknikler

2.2.2.1.1. Basit Doğrusal Regresyon

Regresyon analizi değişkenler arasındaki fonksiyonel ilişkiyi araştıran kavramsal olarak basit bir tekniktir. İlişki, yanıt veya bağımlı değişken ile bir ya da daha fazla açıklayıcı/tahmin edici değişkeni birbirine bağlayan bir denklem veya model biçiminde ifade edilmektedir (Chatterjee ve Hadi, 2015: 1).

Regresyon teorisinin konusu değişkenler arasında var olan ilişkinin fonksiyonel biçimde ifade edilmesi olarak tanımlanmaktadır. Regresyon analizinde bir/birden fazla bağımsız değişken ile bağımlı bir değişken arasındaki ilişkinin açıklanması amaçlanmaktadır. Regresyon analizi yapılırken her bir değişkenin çevresel faktörlerle nasıl ilişkili olduğuna odaklanılmaktadır. Regresyon analizinde bağımlı değişken bir veya daha fazla açıklayıcı değişkenin bir fonksiyonu olarak tanımlanmaktadır (Ter Braak ve Looman, 1995: 29).

Değişkenler arasındaki ilişkinin araştırılması için istatistiksel bir araç olan regresyon analizinde genellikle araştırmacı bir değişken üzerindeki nedensel etkiyi tespit etmeyi amaçlamaktadır. Örneğin fiyat artışının talep üzerindeki etkisi veya para arzında yaşanan değişikliklerin enflasyon üzerine etkisinin araştırılması regresyonun konusu olabilmektedir. Bu tür sorunları araştırmak için araştırmacı, ilgili değişken altında yatan verileri bir araya getirir ve nedensel değişkenlerin, etkiledikleri değişken üzerindeki nicel etkisini tahmin etmek için regresyon kullanmaktadır. Ayrıca tahmin edilen ilişkinin istatistiksel önemi de değerlendirilmektedir (Sykes, 1993: 1).

Regresyon yönteminde sayısal olarak ölçülebilen bir ya da daha fazla değişken üzerine etkisi olduğu varsayılan bir başka değişkenin arasındaki ilişkinin modellenmesidir. Etki eden değişken bağımsız veya açıklayıcı değişken olarak isimlendirilirken, etkilenen değişken ise bağımlı değişken olarak isimlendirilmektedir (Eşidir, 2020: 26).

Regresyon analizi; beklenen yanıtın açıklayıcı değişkenlere nasıl bağlı olduğunu tanımlayan sistematik bir parça ve gözlemlenen yanıtın beklenen yanıtın

sapma şeklini tanımlayan bir hata bölümü olmak üzere iki bölümden oluşan bir yanıt modeline dayanmaktadır. Sistematik kısım bir regresyon denklemi ile belirtilirken, hata kısmı ise hatanın istatistiksel dağılımı ile tanımlanabilir. Basit regresyon formülü (2.1) ile gösterilmektedir (Ter Braak ve Looman, 1995: 30):

$$y = b_0 + b_1x + \varepsilon \quad (2.1)$$

y: yanıt değişkeni (bağımlı değişken vektörü)

x: açıklayıcı değişken (bağımsız değişken)

ε : hata terimi (ortalaması sıfır, varyansı σ^2 olan normal dağılıma sahip rassal bir değişkendir)

b_0 : sabit bir değer

b_1 : ilgili değişkenin katsayısıdır.

2.2.2.1.2. Çoklu Doğrusal Regresyon

Basit doğrusal regresyon yönteminden bağımsız değişken sayısının iki veya daha fazla olması nedeniyle farklılık gösteren çoklu doğrusal regresyon yönteminde bütün ön şartlar basit doğrusal regresyon tekniğinde olduğu gibidir (Şenol, 2008: 186). Pek çok farklı alanda kullanılan regresyon modellerinde genellikle bağımlı değişken tek bir bağımsız değişkenle açıklanamamaktadır. Birden fazla bağımsız değişkenin bağımlı değişken üzerinde etkisi olabileceği gibi bu değişkenler aynı zamanda birbirlerini de etkileyebilmektedir. Bu nedenler dolayısıyla birden fazla bağımsız değişkenin incelenmesi gereken durumlarda basit doğrusal regresyonun kullanılması mümkün olmamaktadır. Birden fazla bağımsız değişkenin etkisinin incelenerek yapılan regresyon analizine çoklu doğrusal regresyon denilmektedir (Şahin, 2020; 33).

Çoklu doğrusal regresyon tekniğinin hedefi, bağımlı ve bağımsız değişkenlerin toplam değişiminin açıklanmasıdır. Çoklu doğrusal regresyon modelinde, modele eklenen bağımsız değişkenlerin hepsinin katkısı önemli olmayabilir. Bu yüzden, hedef (bağımlı) değişkeni en iyi biçimde açıklayacak bağımsız değişkenlerin belirlenerek, katkısı önemsiz olanların modelden çıkartılması gerekmektedir (Kayaalp, Güney ve Cebeci: 2015; 1).

$$Y_i = \beta_0 + \beta_1 \chi_{i1} + \beta_2 \chi_{i2} + \dots \beta_p \chi_{ip} + \varepsilon_i \quad (2.2)$$

β : sabit bir değerdir ve modelde yer alan değişken katsayılarını göstermektedir

ε : tesadüfi hata terimidir

Modele eklenen değişkenler arasında çoklu bağıntı olup olmadığı da dikkat edilmesi gereken bir özelliktir. Çok regresyon modeli içerisindeki değişkenlerin birbirleriyle yüksek seviyede ilişkili olması çoklu bağıntı olarak tanımlanmaktadır. Modele eklenen bağımsız değişkenler içerisinde bu yönde bir ilişki olması durumunda değişkenlerden birinin modele ek bir katkı sağlamadığı anlaşılmaktadır (Kılıç, 2013: 91).

2.2.2.1.3. Doğrusal Olmayan Regresyon

Doğrusal olmayan regresyonun temel fikri, doğrusal regresyon ile benzerdir. Doğrusal olmayan regresyon, tahmin denkleminin doğrusal olmayan bir biçimde bir veya daha fazla bilinmeyen parametreye bağlı olduğu gerçeğiyle karakterize edilmektedir. Doğrusal regresyon genellikle tamamen ampirik bir model oluşturmak için kullanılırken, doğrusal olmayan regresyon ise genellikle yanıt ve tahmin ediciler arasındaki ilişkinin belirli bir işlevsel formu izlediğine inanmak için fiziksel nedenler olduğunda ortaya çıkmaktadır. Doğrusal olmayan regresyon modeli (Smyth, 2002: 1405):

$$Y_i = f(x_i, \theta) + \varepsilon_i, \quad i = 1, \dots, n \quad (2.3)$$

Y_i : yanıt değişkeni (hedef değişken)

f : ortak değişken vektörünün bir fonksiyonu $x_i = (x_{i1}, \dots, x_{ik})^T$ ve

$$\theta = (\theta_1, \dots, \theta_p)^T$$

ε_i : rasgele hata terimidir.

Değişkenler arası ilişki diferansiyel ya da bağımlı ve bağımsız değişkenler arasında yer alan ilişki şekli hakkında doğrudan bilgi sahibi olunamıyorsa doğrusal olmayan regresyon modeli tercih edilmelidir (Şahin, 2020: 33).

2.2.2.1.4. Vektör Otoregresyon

Vektör otoregresyon (VAR) modeli 1980 yılında Sims tarafından geliştirilmiştir. Nedensellik testi modelini temel alan yöntemde iki içsel değişken bulunuyorsa her bir değişken hem kendisi hem de diğer içsel değişken için gecikmeli değerler ile ilişkilendirilmektedir. Vektör otoregresyon modelinin Y_t ve X_t serileri için tanımı (Akyüz, 2018: 185);

$$Y_t = \alpha + \sum_{j=1}^m \beta_j Y_{t-j} + \sum_{j=1}^m \delta_j X_{t-j} + \varepsilon_{1t} \quad (2.4)$$

$$X_t = \alpha + \sum_{j=1}^m \theta_j Y_{t-j} + \sum_{j=1}^m \vartheta_j X_{t-j} + \varepsilon_{2t} \quad (2.5)$$

(2.4) ve (2.5) numaralı formüllerde görüldüğü gibi X 'in gecikmeli değerleri Y değişkenini, Y 'nin gecikmeli değerleri ise X değişkenini etkilemektedir.

VAR modelinde gecikmelerin uzunlukları tespit edilerek etki-tepki nitelikleri incelenmektedir. Bu nitelikler incelenerek beklenmedik durumların değişkenler üzerindeki etkileri ve ne kadar süreyle etkilerinin olduğu gösterilmektedir. Bu inceleme sonucunda ise beklenmedik durumların hangi değişkende olduğu ve bu olay karşısında değişkenin nasıl tepki verdiği anlaşılmaktadır (Şahin, 2020: 35).

2.2.2.2. Korelasyon Katsayısı Analizi

Değişkenlerin birbirleriyle veya değişkenlerin içerisinde yer aldıkları çevreleriyle bir ilişkileri olduğu belirlendiğinde bu ilişkinin derecesi korelasyon katsayısı ile ölçülebilmektedir. Gözlem değerlerine bağlı kalmak koşulu ile $Y = f(X)$ biçiminde tanımlanan fonksiyonel bir ilişkinin derecesinin tespit edilmesi korelasyon analizi ile gerçekleştirilebilmektedir (Şenol, 2008: 196).

Bağımlı veya bağımsız değişken ayrımı gözetmeksizin X ve Y değişkenleri arasında bir ilişki olduğu biliniyorsa, basit korelasyon olarak nitelendirilen bu ilişki -1 ile +1 aralığında değer almaktadır (Yavuz ve Karabulut, 2016:461).

Değişkenler arasında yer alan ilişkinin fonksiyonel olarak ifade edilmesinin yeterli olmadığı durumlarda bile bu değişken ilişkilerinin derecesi öğrenilmek istenebilir. Korelasyon katsayısı yöntemi ile regresyon tekniğinde bulunan Y öngörüsünün gerçek değerlere uygunluğu ölçülebilir. Değişkenler arasındaki ilişki -1

ile +1 aralığında değerler almakta, -1 ters yönlü tam ilişkiyi +1 ise doğru yönlü tam ilişkiyi göstermektedir. Korelasyon katsayısının genel formülü (Eşidir, 2020: 27):

$$r = \pm \sqrt{\frac{\sum (Y - \bar{Y})^2}{\sum (Y - \bar{Y})^2}} \quad (2.6)$$

Korelasyon katsayısı yöntemiyle değişkenler arasındaki ilişkinin derecesi ve bu ilişkinin gücü ölçülmektedir. Korelasyon değişkenler arasındaki ilişkinin gücünü gösterir ancak neden/sonuç ilişkisiyle ilgili bir bilgi vermemektedir (Tütek ve Gümüsoğlu, 2011: 204).

2.2.2.3. Zaman Serisine Dayanan Tahmin Teknikleri

Ekonometrik araştırmalarda en kritik noktalardan birisi, ekonomi modelini oluşturan değişkenlerin sayısal olarak ifade edilebilecek biçime getirilmesidir. Bu yüzden oluşturulan ekonomik modelin reel bir iktisadi duruma uyarlanabilmesi için modelde yer alan değişkenlerin toparlanması modelin kuruluş aşamasında düşünülmelidir. Sayısal verinin oluşmadığı durumlarda deneysel çalışma yapılabilmesi zorlayıcı olacağından, öncelikli olarak verilerin sınırları belirlenerek ekonometrik çalışmanın uygulanabilirliğinin araştırılması gerekmektedir (Sevüktekin ve Çınar, 2014: 1).

Ekonometrik bir araştırmada veriler; çalışılan alanın nitelikleri ve gerçek bilgilerine dayanmaktadır. Oldukça yüksek bir çeşitlilik gösteren bu kaynaklar farklı kaynaklardan elde edilmekte ve birleştirilerek sayısal verilere ulaşılmaktadır. Elde edilen verilerin ekonometrik araştırmalarda kullanılabilmesi için arındırılması gerekmektedir (Intriligator, Bodkin ve Hsiao, 1996: 3).

Değişkenlerin dönemsel olarak birbirini ardına gözlemlendiği sayısal değerler hakkında bilgi sahibi olabilmek için zaman serisi analizi kullanılmaktadır. Gözlemlenen verilerin zaman içerisinde ardışık biçimde yer alması bir koşul değildir ancak zaman aralıklarının düzenli bir dizi biçiminde gelişiminin takip edilmesi analizin doğru biçimde yapılabilmesi için kritik bir öneme sahiptir (Seddighi, Lawyer ve Kator, 2000: 252).

2.2.2.3.1. Hareketli Ortalamalar Süreci MA(q)

Hareketli ortalamalar sürecinde geçmiş veriler baz alınarak ortalama değer hesaplanarak, bu ortalama doğrultusunda ilerleyen dönemler için değişken

davranışları tahminlenmeye çalışılmaktadır. Bu teknikte eldeki en son veri setinin ortalaması alınarak tahmin yapılmaktadır. Hareketli ortalamalar tekniğinin doğası gereği, elde edilen sonuncu veri modele eklenirken ilk eklenen veri modelden çıkarılmaktadır. Hareketli ortalamalar yönteminde araştırmacının belirleyeceği bir k sabiti bulunmaktadır. Tamamen sayısal bir süreç olan zaman serisi sürecinde k sabitinin belirlenmesiyle yöntem yargısal ifadeler de dâhil olmaktadır. Yöntem için yaygın biçimde kullanılan formül (Soysal ve Ömürgönülşen, 2010: 128);

$$\bar{Y}_{t+1} = \frac{Y_t + Y_{t-1} + \dots + Y_{t-k+1}}{k} \quad (2.7)$$

$\bar{Y}_{t+1}$: gelecek döneme yönelik gerçekleştirilen tahmin

Y_t : t zamanındaki gerçek değer

k: ortalamaya dahil edilecek veri sayısıdır.

Hareketli ortalama tekniği yakın geçmişe odaklanarak sadece bir dönemlik bir tahmin yapabilmektedir.

2.2.2.3.2. Ağırlıklı Ortalama Yöntemi

Algoritmik anlamda kolay ve programlanabilirlik açısından elverişli bir yapıya sahip olması nedeniyle yaygın olarak kullanılmakta olan ağırlıklı ortalama yöntemi basitliği nedeniyle pek çok uygulamada etkin sonuçlar vermektedir. Bu teknikte dönemlere farklı ağırlıklandırma yapılmaktadır. Ağırlıklı ortalama yönteminin genel formülü (Eşidir, 2020: 29):

$$z_0 = \frac{\sum_{j=1}^n \mu_c(\bar{z}) \cdot \bar{z}}{\sum_{j=1}^n \mu_c(\bar{z})} \quad (2.8)$$

2.2.2.3.3. Üstel Düzeltme Yöntemi

Geçmiş döneme ait verilere farklı ağırlıklandırmalar yapan yöntemler topluluğudur. Veriler eskidikçe verilen ağırlıkların üstel biçimde azalması üstel

terimi ile ifade edilmektedir. En yakın geçmişteki verilerin geleceğe olan etkisinin geçmiş verilerden daha fazla olması tekniğin başarı oranını arttırmaktadır (Önder ve Hasgöl Kuvat, 2009: 62).

Üstel düzeltme yöntemi verinin mevsimsellik ve trend içermesi durumunda çok başarılı değildir. $t+1$ olarak ifade edilen bir sonraki dönem değeri öngörülme istendiğinde t dönemine ait gerçek değer ile bu dönemin daha önceden tahmin edilen değeri farklı ağırlıklandırılarak toplanmaktadır. Burada α değeri belirlenirken minimum hatalı değer hedeflenmektedir. Üstel düzeltme yöntemine ait en genel formül (Soysal ve Ömürgönülşen, 2010: 128);

$$\bar{y}_{t+1} = \alpha Y_t + (1 - \alpha) \bar{y}_t \quad (2.9)$$

$\bar{y}_{t+1}$: sonraki döneme ait tahmin değeri

Y_t : içerisinde bulunulan dönemin gerçek değeri

$\bar{y}_t$: içerisinde bulunulan döneme ait tahmin değeri

α : düzeltme katsayısı

Üstel düzeltme tekniği günümüzde sıklıkla tercih edilen tahmin yöntemlerinden biridir. Yöntemin sıklıkla tercih edilmesi açık, anlaşılır ve farklı olaylara kolay adaptasyon sağlayabiliyor olmasıdır. Yakın dönem gözlemleri eski gözlem ve verilere oranla bu metot için daha önemlidir (Yağımlı ve Ergin, 2017: 118).

2.2.2.3.4. Box-Jenkins Yöntemi

ARIMA modeli olarak bilinen bu model, doğrusal zaman serisi tekniğinde oldukça yaygın kullanılan bir tekniktir. Bu teknikte bağımlı değişkenin gecikmeli değerleri üzerinden rassal hata ile açıklandığı varsayılmaktadır. Box-Jenkins tekniğinde modele karar verme, modelin parametresinin belirlenmesi ve model uygunluğunun test edilmesi süreçlerini içermektedir. Bu işlem adımları sonrası model artık tahmin amacıyla kullanıma hazır durumdadır. Modelin belirlenmesi aşamasında zaman serisi tekniğinin uygulanabilirliği açısından serinin hem ortalama hem de varyansta durağanlığı kontrol edilir çünkü durağan olmayan seriye bazı olasılık kuralları uygulanamayacağı gibi belirli bir modelde de gösterilememektedir. İkinci aşama olan model parametrelerinin belirlenmesinde çeşitli paket programlar

yardımıyla en küçük kareler yöntemi veya en çok olabilirlik gibi teknikler kullanılmaktadır. Parametrelerin anlamlılığı ise yine paket programlar yardımıyla yapılmaktadır. Son aşama olan model uygunluğunun testi ise hata kontrollerinin istatistiksel kriterlerle yapılmasıdır (Keskin Benli ve Yıldız, 2014: 215).

Bu yöntem yapısının güçlü olması ve esnekliği nedeniyle pek çok alanda sıklıkla tercih edilmektedir. Modeli en çok tercih edilebilir kılan özelliği ise zaman serisi süreci için en uyumlu modelin belirlenmesine imkân sunmasıdır (Kurt ve Senal, 2018: 235).

- Otoregresif Hareketli Ortalamalar (AR-MA): En genel durağan model olan ARMA ayrıca geçmiş gözlem ve hata teriminin de doğrusal bir fonksiyonu olarak ifade edilmektedir. ARMA(p,q) modeline ilişkin en genel formül ise (Eşidir, 2020: 31):

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \delta + a_t + \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (2.10)$$

$Y_{t-1}, Y_{t-2}, \dots, Y_{t-p}$: geçmişe ait gözlem değerleri

$\phi_1, \phi_2, \dots, \phi_p$: geçmişe ait gözlem değerlerinin katsayıları

δ : sabit bir değeri

$a_t, a_{t-1}, a_{t-2}, \dots, a_{t-q}$: hata terimleri

$\theta_1, \theta_2, \dots, \theta_q$: hata terimleriyle ilgili katsayılarıdır.

- Ororegresif Bütünleşik Hareketli Ortalamalar (ARIMA): Zaman serilerinde kullanılan ve olası gelecek değerleri tahmin eden ARIMA yönteminde serilerin rasgele bir zamandaki değerleri, geçmiş dönem değerleri ve tahmindeki hata terimlerinden oluşan doğrusal bir eşitlikle belirlenmektedir. AR(p) ve MA(q) süreçlerinin birleşiminden oluşan ARIMA(p,d,q) en yaygın ifadesi (Eşidir, 2020: 31):

$$u_t = p_1 u_{t-1} + p_2 u_{t-2} + \dots + p_p u_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

p : AR(p) modelinden edinilen otokorelasyon katsayısı

θ : MA(q) modelinin katsayısını belirtmektedir.

ÜÇÜNCÜ BÖLÜM

YAPAY SİNİR AĞLARI

Son on yıllardır pek çok sayıda basit işleve sahip akıllı makineler geliştirebilmek bilim ve mühendisliğin temel hedefi olmuştur. 1940'lı yıllarda insan beyninin sahip olduğu bilişsel işlevi kopyalamak isteyen araştırmacılar biyolojik nöronların en basit haliyle donanım ve yazılım modellerini içeren etkileşimli sistemler geliştirmişlerdir. İnsan beyninin ilk sistematik modeli olan çalışma McCulloch ve Pitts tarafından 1943 yılında yayınlanmıştır. 1947 yılında aynı araştırmacılar tarafından tek katmanlı bir algılayıcı yardımıyla örüntü tanıma için paradigma araştırmaları gerçekleştirilmiştir. 1950 ve 1960'lı yıllarda farklı bir grup araştırmacı ise ilk yapay sinir ağını üretebilmek için biyolojik ve psikolojik kavrayışları birleştirmişlerdir. Yeni geliştirilen bu sistem başlangıçta elektronik devre biçiminde uygulanırken daha sonra esnek bir bilgisayar simülasyonuna dönüştürülmüştür. 1970'lerde Grossberg, Kohonen, Widrow ve diğerleri gibi birçok öncü araştırmacı tarafından yapay sinir ağlarıyla ilgili daha ileri araştırmalar devam etmesine rağmen bu çalışmalar nispeten daha az ilgi gördü. Sinir ağları alanındaki ilginin son zamanlarda yeniden canlanmasının başlıca faktörleri, Rosenblatt, Widrow ve Hoff tarafından gerçekleştirilen karmaşık, çok katmanlı bir ağda öğrenme ile ilgili çalışmalarının genişletilmesidir (Zilouchian, 2001: 1).


Yapay sinir ağı teknolojisinin geliştirilmesindeki temel motivasyon kaynağı insan beyninin gerçekleştirebildiği karmaşık işlemlerin kopyalanmaya çalışılmasıdır. Yapay sinir ağı teknolojisinde günümüzde ulaşılan nokta; öngörü geliştirme, öngörüye dayalı model geliştirme, örüntüleri tanıyabilme gibi yeteneklerin endüstri, savunma, finans ve sağlık gibi alanlarda kullanılabilmesidir. Algoritmik bir yapıda olmaması, farklı senaryolara uyarlanabilmesi ve paralel hesaplama yeteneği, öğrenme yeteneği yapay sinir ağlarının temel özellikleri içerisinde yer almaktadır. Yapay sinir ağlarına ilişkin karakteristik niteliklerin bazıları ise (Öztemel, 2003: 31):

- Yapay sinir ağı denk durumlara karşı aynı kararları alabilmesi,
- Geleneksel programlama yöntemlerinden bilgi işleme sistemleriyle ayrılırlar,
- Elde edilen bilgi ağ bağlantılarının ağırlıkları ile ölçülür ve bu bağlantılarda depolanır,
- Güvenilirlik analizi eğitim ve performans analiziyle gerçekleştirilir,

- Örnekler yardımıyla öğrenme süreci gerçekleştirilir,
- Tanımlı olmayan örnekler üzerinden genelleme süreciyle yeni bilgi edinilir,
- Örnekler sınıflandırılıp ilişkilendirilebilir,
- Yapay sinir ağı yeni bir olay karşısında kendini organize ederek öğrenebilir,
- Hata toleransı bulunan yapay sinir ağlarında bilgi eksikliği yaşanması durumunda sonuç başarısız olmaz,
- Belirsiz veya bulanık veriler de işlenebilmektedir,
- Bilgileri ağı yaymış olarak saklaması nedeniyle dağınık bir bellek yapısına sahiptirler.

Yapay sinir ağları iki veya daha fazla nöronun birleştirilmesiyle elde edilmektedir. Gerçek bir yaşam problemini çözme aşamasında tek bir yapay nöronun neredeyse hiçbir faydası bulunmazken, yapay sinir ağlarında tek bir nöron da problem çözme üzerinde etkilidir. Yapay sinir ağlarındaki temel yapı taşı olan yapay nöronlar bilgileri doğrusal olmayan, dağıtılmış, paralel ve yerel bir biçimde işleyerek karmaşık gerçek hayat problemlerini çözme yeteneğine sahiptir. Bireysel yapay nöronların birbirlerine bağlanma şekli bir yapay sinir ağının topolojisi, mimarisi veya grafiği şeklinde isimlendirilmektedir. Aradaki bağlantının çeşitli şekillerde yapılabiliyor olması, iki temel sınıfa ayrılan yapay sinir ağı pek çok farklı topoloji ile sonuçlanmaktadır (Suzuki, 2011: 6).

Şekil 5: Yapay Sinir Ağı Çalışma Prensibi



Kaynak: Suzuki, 2011: 3 kaynağından alınarak yeniden düzenlenmiştir.

Yapay sinir ağılarına olan ilgi, ağların insan beynini taklit etme yeteneğinin yanı sıra öğrenme ve yanıt verme yeteneğinden kaynaklanmaktadır. Yapay sinir ağları çok sayıda uygulamada kullanılmış ve çeşitli alanlarda karmaşık işlevleri yerine getirmede etkili olduğu kanıtlanmıştır. Bunlar, örüntü tanıma, sınıflandırma, görme, kontrol sistemleri ve tahmin uygulamalarını içermektedir. Uyarlama veya öğrenme, yapay sinir ağı modelinde sinir ağı araştırmasının ana odak noktasıdır. Tahmine dayalı modellemede ise amaç, bir dizi girdi modelini bir dizi çıktı modeline eşlemektir. Yapay sinir ağı bu görevi, ağı sunulan bir dizi girdi/çıktı veri setinden öğrenerek gerçekleştirir. Eğitilen ağ daha sonra, ilgili çıktıyı tahmin etmek veya tahmin etmek için öğrendiklerini uygulamak için kullanmaktadır (Zilouchian, 2001: 1).


3.1. SİNİR HÜCRESİ

İnsan beyninde gerçekleşen çevreyi algılama, düşünerek karar verme ve öğrenme gibi fonksiyonlar geçmişten bu güne kadar merak edilmiştir. İnsan beyninde gerçekleşen bilişsel işlevin çoğu, hala bilim insanları için gizemini korumaktadır. İnsan beyninde gerçekleşen; bilgilerin kalıplar halinde saklanması, bu kalıplara ihtiyaç duyulduğunda kullanılarak yaşanan problemlerin çözülmesi bilim insanlarına bu sistematığı örnek alabilen araçlar geliştirme konusunda motivasyon kaynağı olmuştur. Bu sistematığı kullanarak herhangi bir yardıma ihtiyaç duyulmaksızın önceden öğrenilen bilgilerin kullanılarak yeni bilgilerin üretilmesi veya yeni bilgi keşiflerinin yapılabileceği bilgisayar yazılımları geliştirilmiştir (Dayı, 2012: 34).

İnsan beyninin gerçekleştirebildiği işlevleri taklit etme fikriyle geliştirilen bu modeller bilgisayar algoritmaları ve yazılım endüstrinde büyük bir yenilik olarak görülmektedir. İnsan beyninde gerçekleşen bilgileri hatırlama, düşünerek karar verme ve geçmiş deneyimlerimizi yeni eylemlerimize uygulama yeteneklerini sağlayan yaklaşık 100 milyar nöron bulunmaktadır. Her bir nöron diğer nöronlar ile 200 bin kadar farklı bağlantı kurabilir. İnsan beynindeki öğrenme ve genetik algoritma yetenekleri nöronlar arasındaki bu bağlantılar ile mümkün olabilmektedir. Nöronlar pek çok alt sistem ve kontrol mekanizması bulunan karmaşık bir yapıdadır. Alınan veriler elektrokimyasal yollar ile diğer nöronlara iletilmektedir (Çavuşoğlu, 2021: 50).

İnsan beyninde insanların bilişsel, algısal ve kontrol gibi görevlerde başarılı olmasını sağlayan devasa sinir ağları bulunmaktadır. İnsan beyni yüz tanıma veya konuşma gibi hesaplama gerektiren algısal eylemlerle, vücut hareketleri gibi kontrol faaliyetlerini yerine getirebilmek için gereken hesaplama yeteneklerine sahiptir. Beynin avantajı sahip olduğu paralellliği etkili biçimde kullanabilmesi ve kesin olmayan bilgiyi işleyebilme yeteneğidir. İnsan beyninde birbirine bağlı 10 milyardan fazla nöron barındıran bir koleksiyondur. Her nöron bilgiyi alma, işleme ve iletme için biyokimyasal reaksiyon kullanan bir hücredir. Şekil 6’da görülen dendrit adı verilen ağaç benzeri sinir lifi ağları; hücre çekirdeğinin bulunduğu hücre gövdesi veya somaya bağlanmaktadır. Aksonlar hücre gövdesinden uzanıp ipliklere ve alt ipliklere ayrılarak, sinaptik terminaller veya sinapslar yoluyla diğer nöronlara bağlanan uzun liflerdir.

Şekil 6: Biyolojik Bir Nöronun Bölümleri




Kaynak: Abraham, 2005: 902’den alınarak yeniden düzenlenmiştir.

Sinapslarda ise sinyallerin bir nörondan diğerine iletilmesi, bağlantının gönderici ucundan belirli verici maddelerin salındığı karmaşık bir kimyasal süreçtir. Etki; alıcı hücrenin gövdesi içindeki elektrik potansiyelini yükseltmek ve azaltmaktır. Potansiyel bir eşiğe ulaştığında aksona bir titreşim gönderilerek hücre ateşlenmektedir (Abraham, 2005: 901).

3.2. YAPAY SİNİR HÜCRESİ

Şekil 7: Yapay Sinir Hücresi



Kaynak: Suzuki, 2011: 5 kaynağından alınarak yeniden düzenlenmiştir.

Her yapay sinir ağının temel yapı taşı olan yapay nöron; tasarımı ve nitelikleri bakımından beyin, omurilik ve periferik gangliyonlar içeren biyolojik sinir sisteminin temel yapı taşı olan biyolojik nöronun gözlemlenerek oluşturulan biçimidir. Biyolojik nörondaki bilgi dendrit aracılığıyla nörona gelir, soma bilgiyi işleyerek akson yoluyla iletmektedir. Yapay nörona ise bilgi ağırlıklandırılan girdiler aracılığıyla yapay bir nöronun gövdesine gelmektedir. Yapay nöronun gövdesi daha sonra ağırlıklı girdileri toplayarak bu toplamı bir fonksiyon yardımıyla işlemektedir. Bu işlem sonucunda yapay bir nöron işlenen bilgiyi çıktıları kullanarak iletmektedir. Yapay nöron modelindeki sadeliğin faydası aşağıdaki formülle ifade edilebilir (Suzuki, 2011: 5):

$$y(k) = F\left(\sum_{i=0}^m w_i(k) * x_i(k) + b\right) \quad (2.11)$$

$x_i(k)$: k ayrık zamandaki girdi değeridir, burada i 0'dan m'ye gider.

$w_i(k)$: ayrık zamanda ağırlık değeridir k burada i 0'dan m'ye gider.

b : yanlılık

F : transfer fonksiyonudur

$y(k)$: ayrık zamandaki çıkış değeridir.

Yapay nöron modeline ait formül 2.11'de görüldüğü gibi modeldeki en büyük bilinmeyen değişken transfer fonksiyonudur. Transfer fonksiyonu yapay nöronun özelliklerini tanımlayan herhangi bir matematiksel fonksiyon olabilir. Bu fonksiyon yapay sinir ağını çözmesi gereken; adım, doğrusal veya doğrusal olmayan işlevler içerisinde seçilen bir problem temeline dayanmaktadır. Adım işlevinin yalnızca iki olası çıkış değeri bulunmaktadır. Burada giriş değeri belirli bir eşiği karşılırsa çıkış değeri tek bir değerle sonuçlanır ancak çıkış değeri belirli bir eşiği karşılamazsa farklı bir çıkış değeriyle sonuçlanmaktadır. Bu durum 2.12 numaralı denklemle ifade edilmektedir (Suzuki, 2011: 6):

$$y = \begin{cases} 1, w_i x_i \geq \text{eşikdeğer} \\ 0, w_i x_i < \text{eşikdeğer} \end{cases} \quad (2.12)$$

Yapay nöronlarda kullanılan transfer fonksiyonu yapay nöron algılayıcısı olarak isimlendirilmektedir. Çok katmanlı algılayıcı sınıflandırma problemlerini çözmek için kullanılır ve bu nedenle genellikle yapay sinir ağının son katmanında bulunmaktadır. Fonksiyonun doğrusal olması durumunda yapay nöron, ağırlıklı girdi

ve yanlılığın toplamı üzerinde basit doğrusal bir dönüşüm uygulanır. Bu tarzdaki bir yapay nöron yapay sinir ağlarının giriş katmanında yaygın olarak kullanılan algılayıcılardan farklıdır. Doğrusal olmayan bir fonksiyon tercih edildiğinde ise en yaygın kullanılan sigmoid fonksiyonudur (Suzuki, 2011: 6).

3.3. YAPAY SİNİR AĞININ ÖĞRENMESİ

Yapay sinir ağında öğrenme, belirli bir ağın düğümleri arasındaki bağlantı ağırlıklarını değiştirmeyi ifade etmektedir. Öğrenme bir sinir ağının ağırlıklar ve yanlılık gibi rasgele değerli parametrelerinin, ağın gömülü olduğu ortamda sürekli bir simülasyon sürecine tabi tutularak uyarlanmasıdır. Öğrenme hızı ağın uyarlanma hızı olarak tanımlanmaktadır. Öğrenme türü ise parametre değişikliğinin gerçekleşme şekli ile belirlenmektedir. Öğrenme; denetimli, denetimsiz ve takviyeli öğrenme olarak sınırlandırılmaktadır. Denetimli öğrenme yönteminde sistemin düzgün biçimde çalışıp çalışmadığı, istenen bir yanıtı belirtebilirliği, sistem yanıtlarının kabul edilebilirliğinin doğrulanması ya da sistem performansındaki hata miktarının belirlenmesi için bir öğrenme yapısı bulunmaktadır. Bu yöntem hiçbir bilginin bulunmadığı, öğrenmenin farklı örnek veriler veya ortamı inceleyen sistem tarafından bilişsel olarak elde edileceği denetimsiz öğrenmenin aksine, bireyin eğitilmesine benzer bir niteliğe sahiptir. Yapay sinir ağında girdiler istenen çıktının üretilebileceği şekilde yapılandırılmalıdır. Bu yapılandırma gücünün belirlenmesinde apriori tekniği ile ağırlıklar açıkça belirlenebileceği gibi sinir ağının öğrenme kalıpları beslenerek çeşitli öğrenme kuralları çerçevesinde ağırlıkların değiştirilmesine izin verilerek ağın eğitimi sağlanabilmektedir (Dongare, Kharde ve Kachare, 2012: 192).

3.3.1. Denetimli Öğrenme

Denetimli öğrenme yapay sinir ağı parametrelerinin eğitim verileri kullanılarak belirlendiği bir makine öğrenmesi yöntemidir. Öğrenen yapay sinir ağının görevi, çıkış değeri görüldükten sonra geçerli bir giriş değeri için parametrelerin değerinin ayarlanmasıdır. Eğitim verileri, veri vektörü içerisinde temsil edilen girdi ve istenen çıktı değerlerinden oluşmaktadır (Suzuki, 2011: 13).

Denetimli öğrenme ile temel fonksiyon parametrelerinin belirlenmesi tipik olarak hesaplama açısından yoğun ve hata fonksiyonunun minimum değerini bulma

eğilimi olan, doğrusal olmayan bir optimizasyon problemidir. Eğitim prosedürüyle ilgili temel fonksiyonların iyi belirlenmesi gereksiz hesaplamalardan kaçınarak süreci önemli ölçüde hızlandırabilmektedir (Bishop, 1995: 191).

Denetimli öğrenme yapay sinir ağının girdi sağlatıktan sonra çıktı modellerini eşleştirerek eğitildiği ilişkisel bir öğrenme metodudur. Bu girdi-çıktı ikilileri harici bir eğitmen veya yapay sinir ağı içerisindeki kendi kendini denetleyen bir sistem tarafından gerçekleştirilebilmektedir. Örneğin; bir insan iskeleti keşfi yapıldıktan sonra cinsiyet belirlemesi yapılması gerekmektedir. Bu belirleme yapılırken erkek ve dişi iskeletlerin daha önceden belirlenen özellikleri dikkate alınarak bir sınıflandırma yapılabilmektedir. Geçmiş örneklerin incelenmesi eğitim veri seti olarak tanımlanmaktadır. Bu süreç denetimli öğrenmenin bir örneğidir ve öğrenme süreci sonunda yeni keşfedilen iskeletin cinsiyetini tanımlamak için kullanılabilir (Dongare, Kharde ve Kachare, 2012; 192).

Denetimli öğrenme yönteminde yapay sinir ağının parametreleri, eğitim vektör verisi ve hata değerlerinin etkisiyle belirlenmektedir. Bu süreç yapay sinir ağının süreç sonunda öğrenimi taklit etmesini gerçekleştirebilmek için tekrar tekrar işletilmektedir. Böylece öğrenme sürecinde kullanılacak çevre, eğitilip sinir ağına aktarılacak uzun süreli hafıza olarak tanımlanan sabit sinaps ağırlıkları şeklinde depolanmaktadır. Bu sonuca erişildiğinde öğretme işlemi sonlanır ve yapay sinir ağının çevreyi tamamen kendi başına algılamasına izin verilmektedir. Bu teknikteki en iyi örnekler geri yayılım algoritması, delta kuralı ve algılayıcı kuralda görülmektedir (Çavuşoğlu, 2021: 54).

Bir denetimli öğrenme problemini çözebilmek için gereken adımlar (Suzuki, 2011: 13);

- Eğitim örneklerinin türü belirlenmelidir,
- Verilen problemi tatmin edici biçimde yanıtlayabilen bir eğitim veri seti toplanmalıdır,
- Kullanılacak yapay sinir ağının anlayabileceği şekilde eğitim veri seti tanımlanmalıdır,
- Öğrenme ve öğrenme sonrasında test veri seti ile öğrenilen yapay sinir ağının performansı test edilmelidir. Test veri seti öğrenme sırasında yapay sinir ağına tanıtılmayan verilerden oluşmaktadır.

3.3.2. Denetimsiz Öğrenme

Denetimsiz öğrenme bir çıktı biriminin girdi içerisindeki örüntü kümelerine yanıt kendi kendini eğittiği bir organizasyondur. Bu paradigmada sistemin girdi popülasyonunun istatistiksel olarak göze çarpan özelliklerini keşfetmesi gerekmektedir. Denetimli öğrenmeden farklı olarak keşfedilen kalıpların sınıflandırılacağı bir ön kategori bulunmamaktadır. Bunun yerine sistem girdi uyarılarının kendini temsil etme özelliğini geliştirmelidir. Örneğin bir dizi iskelet parçasının spesifik bir dinazor türüne ait olup olmadığını veya farklı türlere ayrılması gerekliliği olup olmadığının belirlenebilmesi için her bir iskelet parçasının türünü açıkça tanımlayacak hiçbir örnek veri seti olmayabilir. Bu durumda araştırmacının parçaların aynı türe ait olarak tanımlanması için yeterince benzer olmadığını veya farklı türler halinde gruplandırılacak kadar büyük olup olmadığını belirlemelidir. Bu durum iskeletler arasındaki farklılıkların büyüklüklerinin tahmin edilmesini içeren denetimsiz bir öğrenme sürecidir (Dongare, Kharde ve Kachare, 2012; 192).

Denetimsiz öğrenme tekniği eldeki veriye ve bir bir maliyet fonksiyonuna göre bir yapay sinir ağının parametrelerini belirlemede kullanılan bir makine öğrenmesi tekniğidir. Maliyet fonksiyonu görev formülasyonu tarafından belirlenen herhangi bir fonksiyon olabilir. Denetimsiz öğrenme tekniğinde çoğunlukla istatistik modelleme, filtreleme ve kümeleme gibi tahmin problemlerinin alanına giren uygulamalarda kullanılmaktadır. Denetimsiz öğrenme algoritmasında verilerin nasıl organize edildiği tespit edilmeye çalışılmaktadır. Yapay sinir ağına tekniğinde denetimsiz öğrenme algoritması veri kümeleme veya sınıflandırma gibi uygulamalarda yaygın biçimde kullanılmaktadır (Suzuki, 2011; 14).

Denetimsiz öğrenme algoritmasında öğrenme prosedürü belirli veri desenlerini genel veri deseni koleksiyonunun istatistiksel yapısını yansıtacak biçimde temsil etmeye çalışmaktadır. En yaygın denetimsiz öğrenme yöntemi, verilerdeki gizli kalıp veya gruplandırmayı bulmada keşifsel veri analizi için kullanılan kümeleme analizi yöntemidir. Kümeler, öklid veya olasılıksal uzaklık gibi metriklerle göre tanımlanan bir benzerlik ölçüsü kullanarak modellenmektedir (Örs, 2017; 32).

Bir eğitici bilgi vesayeti altında gerçekleşen denetimli öğrenme algoritmasının aksine denetimsiz öğrenme algoritmasında, öğrenme sürecini destekleyen bir eğitmen bulunmamaktadır. Yani denetimsiz öğrenme algoritması ile çalışan yapay sinir ağında öğrenilecek kazanımın önceden bir örneği

bulunmamaktadır. Denetimsiz öğrenme algoritmasının iki farklı kategorisi bulunmaktadır bunlardan ilki pekiştirmeli öğrenme; bir çeşit denetimli öğrenme algoritmasına benzer olsa da her ağ girişi için doğru çıktının sağlanması yerine çıktının doğruluk seviyesini ölçerek bir derecelendirme yapılmaktadır. İkincisi denetimsiz öğrenmede ise; basit girdi veya gizlenmiş nöronlardan meydana gelmektedir. Denetimsiz öğrenme algoritmasıyla çalışan yapay sinir ağı; farklı giriş modeli türlerinin farklı gizli düğüm kümeleriyle ilişkilendirilmesi yoluyla öğrenme işlemini gerçekleştirmektedir. Eğitilerek farklı gizli nöron veya farklı girdi desen gruplarına cevap vermektedir (Çavuşoğlu, 2021; 54).

3.3.3. Pekiştirmeli Öğrenme

Pekiştirmeli öğrenme yöntemi denetimli ve denetimsiz öğrenme yöntemlerinin bir ara formu olarak kabul edilmektedir. Bu öğrenme türünde makine öğrenmesi tekniği çevre üzerine bazı işlemler gerçekleştirir ve gelen geribildirimlerin yanıtlarını alır. Öğrenme sistemi çevresel tepkiye göre eylemini ödüllendirici veya cezalandırıcı olarak derecelendirerek buna göre parametre değerlerini belirlemektedir. Genel anlamda bir denge durumu oluşana kadar parametre değeri güncellenmeye devam edilir. Kendi kendine organize olan sinirsel öğrenme pekiştirmeli öğrenme kategorisi altında sınıflandırılmaktadır (Dongare, Kharde ve Kachare, 2012; 192).

Genellikle verilerin önceden verilmediği ve çevre koşulları ile etkileşimleri sonucunda yapay sinir ağı parametrelerinin belirlendiği bir makine öğrenmesi tekniğidir. Pekiştirmeli öğrenme tekniği yapay sinir ağının uzun vadede ödül kavramını en üst seviyeye çıkarmak için bir ortamda nasıl eylemler yapması gerektiğiyle ilgilidir. Pekiştirmeli öğrenme yapay sinir ağının genel öğrenme algoritmasının bir parçası olarak sıklıkla tercih edilmektedir. Pekiştirmeli öğrenmede maksimize edilmesi gereken dönüş fonksiyonu tamamlandıktan sonra en başarılı olan prensibin bulunması için çeşitli algoritmalar kullanılmaktadır. Naive brute force algoritması öncelikle her olası prensip için geri dönüş fonksiyonu hesaplar ve en büyük getiriye sahip prensibi tercih eder. Pekiştirmeli öğrenme yönteminin zayıf noktası sonsuz sayıdaki prensip durumudur. Bu risk değer fonksiyonu yaklaşımı veya doğrudan prensip tahmini ile giderilebilmektedir. Pekiştirmeli öğrenme yöntemi özellikle uzun ve kısa vadeli ödül takasını içeren problemler için uygundur.

Pekiştirmeli öğrenme yöntemi robot kontrolü, telekomünikasyon ve satranç gibi oyunlar ile diğer sıralı karar verme görevleri içeren problemlerde başarıyla uygulanmaktadır (Suzuki, 2011; 15) .

Denetimli öğrenme yönteminde olduğu gibi pekiştirmeli öğrenme tekniğinde de bir danışman öğrenmeye yardımcı olmaktadır. Denetimli öğrenmeden farklı biçimde algoritmaya sadece girdi değeri verilir ancak hedeflenen çıktılar verilmez. Yapay sinir ağının kendi çıktı değerlerini üretmesi beklenir ve danışman çıktı değerlerinin doğruluk düzeyini belirten bir değeri belirtir. Danışmandan alınan değeri doğrultusunda bağlantıların ağırlıklandırılmalı güncellenerek öğrenme süreci devam ettirilmektedir. Pekiştirmeli öğrenme metodunu kullanan algoritmalara en önemli örnek LVQ ağıdır. Optimizasyon problemleri çözümünde veya genetik algoritmalar pekiştirmeli öğrenme yöntemine en yaygın örneklerdendir (Bayır, 2006: 28).

3.4. YAPAY SİNİR AĞININ SINIFLANDIRILMASI

Yapay sinir ağı parametrelendirilerek, doğrusal olmayan herhangi bir işlevi taklit etme yeteneğine sahiptir. Yapay sinir ağı; bağlantı yapısı, öğrenme metodu veya mimari yapılarına göre sınıflandırılabilir (Çavuşoğlu, 2021:52).

3.4.1. Yapılarına Göre Yapay Sinir Ağlarının Sınıflandırılması


Bilgi işleme için hesaplama modeli kullanan birbirine bağlı birimler veya nöronlar kümesi olan yapay sinir ağının en basit hali üç katman içermektedir. Nöronların giriş katmanı olan ilk katmandan sonra orta katman ve çıktıların alındığı son katman yer almaktadır. Yapay sinir ağı karmaşık ve doğrusal olmayan problemlerin yanı sıra deneyimlediklerinden de hızlı bir biçimde öğrenebilmektedir (Iqbal ve Aftab, 2019; 21).

3.4.1.1. İleri Beslemeli Yapay Sinir Ağı

Yapay sinir ağının ileri beslemeli modeli tek yönlü sinyal akışına izin vermektedir. İleri beslemeli yapay sinir ağı bu teknolojinin en basit halidir. Bilginin yalnızca ileri yönlü gizli ve hedef olarak çıkış katmanına soğru ilerleyebildiği bu ağı yapısında sistemde bir hafıza bulunmamaktadır. Statik ağda

denilen ileri beslemeli yapay sinir ağında sinyaller her zaman sadece ileri yönlü olarak taşınabilmektedir (Aşkın, İskender ve Mamızadeh, 2011; 906).

Şekil 8: İleri Beslemeli Yapay Sinir Ağı



Kaynak: <https://www.derinogrenme.com/2017/03/04/yapay-sinir-aglari/> Adresinden alınarak yeniden düzenlenmiştir.

İleri beslemeli bir topolojiye sahip olan yapay sinir ağlarında bulunan tek koşul; bilginin geri dönüş olmadan girişten çıkışa yalnızca bir yönde akması gerekliliğidir. Katman sayısı, bireysel yapay nöronlarda kullanılan transfer fonksiyonunun türü veya bireysel yapay nöronlar arasındaki bağlantı sayısı konusunda herhangi bir sınırlama bulunmamaktadır. En basit ileri beslemeli yapay sinir ağı yalnızca doğrusal ayrılabilir problemleri öğrenebilen tek bir algılayıcıdır (Suzuki, 2011: 7).

Yapay sinir ağının ilk ve en basit türü olan bu yapıda, bilgi yalnızca tek bir yönde ilerleyebilmektedir. Girdilerden elde edilen bilgi herhangi bir döngü veya geri beslemeyle temas etmeden eğer bulunuyorsa gizli katmanlar üzerinden ilerleyerek çıktıdan sonucu göstermektedir (Kumar, 2016: 159). Yani; bir katmanda yer alan sinir hücreleri kendisinden önce yer alan sinir hücresinden beslenmektedir. Bu model katman sayısı açısından tek katmanlı ve çok katmanlı ileri beslemeli yapay sinir ağı olarak gruplandırılmaktadır. İleri beslemeli yapay sinir ağı modeli çoğunlukla; işaret işleme, nesne tanımlama, sistem tanımlama ve denetleme gibi pek çok uygulamalı alanda başarıyla kullanılmaktadır (Sarı, 2016: 43).


3.4.1.2. Geri Yayılımlı Yapay Sinir Ağı

Kelime anlamı olarak ‘geri yayılım’; çıktı katmanlardan elde edilen hatanın geriye yayılmasını ifade etmektedir. Yapay sinir ağı türlerinde hemen hemen her problemin çözümünde kolaylıkla uygulanabilen bir yapıda olan bu öğrenme kuralı; aslında ileri beslemeli bir yapıda olmasına rağmen hata payının geriye doğru yayılması nedeniyle geri beslemeli olarak tanımlanmaktadır (Lippman, 1988).

Geri beslemeli yapay sinir ağı modelinde minimum bir hücrenin çıkışındaki değer kendisi ya da başka bir hücrenin girişinde yer alacak değer olarak tanımlanabilmektedir. Böylece geri besleme tekniği genellikle bir gecikme faktörü de içermektedir. Bu teknikte kullanılan geri besleme yöntemi hem mevcut katmanlarda hem de farklı katmanlar arasında gerçekleştirilebilmektedir. Bu nedenle dinamik ve doğrusal olmayan bir yapıdadır (Serttaş, 2011: 35).

Geri besleme tekniği; ilki yayılma ikincisi ise uyum sağlama olarak tanımlanan ve iki aşamadan oluşan bir süreçtir. Geri besleme modeli katmanlar arasında ilişki sağlanan çok katmanlı, ileri beslemeli ve denetimli öğrenme ile eğitilen bir ağ olarak tanımlanmaktadır. Geri besleme tekniği standart olarak sistemdeki hataları çıkıştan başlayıp girişe olacak şekilde geriye doğru azaltarak işlemektedir. Bu işleyiş modelin isimlendirmesinin temelini de oluşturmaktadır. Geri beslemeli modelde de yine ileri beslemeli modellerde olduğu gibi giriş, gizli ve çıkış katmanları olmak üzere üç temel katman bulunmaktadır (Sharma ve Chopra, 2013: 33).

Şekil 9: Geri Yayılımlı Yapay Sinir Ağı




Kaynak: Abiodun vd. 2018: 8 kaynağından alınarak yeniden düzenlenmiştir.

Denetimsiz öğrenme tekniğinin kullanıldığı ağ yapılarında bulunan geri yayılım mimarisi; çıkış ve ara katmanlarda yer alan çıkışların önceki katmanın sinir girişlerine bağlı olan bir geri yayılım mekanizmasına sahiptir (Elmas, 2007: 57). Geri yayımlı yapay sinir ağlarının uygulama alanları arasında; matematiksel ispatlar, sismik veri oluşturulması, tıp, bilim, mühendislik, sınıflandırma, fonksiyon tahmini ve zaman serisi tahmini gibi nitelikler yer almaktadır. Diğer sinir ağı yapılarından farkı giriş dizisi için bir zaman belirtilmediğinden, girişin bir ağaç biçiminde işlenmesi gereken hiyerarşik bir ağıdır (Abiodun vd. 2018: 8).

3.4.1.3. Tekrarlayan Yapay Sinir Ağı

Tekrarlı yapay sinir ağı modeli minimum bir geri yayılım döngüsü ile ileri beslemeli yapay sinir ağından ayrılmaktadır. Tekrarlı bir yapay sinir ağında her nöronun çıktısı geriye kalan tüm nöron girişlerini besleyen bir nöron katmanından meydana gelebilmektedir. Yapay sinir ağı içerisinde kendisine geri bildirim yapılmamaktadır, ağdan gerçekleştirilen geribildirim ise bir nöronun çıktısının aynı anda girdisi olarak geri beslendiği yapıdır. Tekrarlı yapay sinir ağı tek veya birden fazla katmanlı olabilmektedir. Gizli nöronları bulunan tekrarlı bir ağda geri besleme bağlantıları hem gizli nöronlardan hem de gizli nöronlardan oluşabilmektedir. Tekrarlı ağda bulunan geri besleme ağın hem öğrenme yeteneğini hem de performansını oldukça büyük oranda etkilemektedir. Tekrarlı yapay sinir ağındaki ara katmanların hem ileriye hem de ağa tekrar gönderilerek işlenmesi bu tekniğin gücünü de arttırmaktadır (Genç Kavas, 2019: 133).

Şekil 10: Tekrarlı Yapay Sinir Ağı



Kaynak: Suzuki, 2011: 8 Kaynağından alınarak tekrar düzenlenmiştir.

Şekil 10 kendini tamamen tekrarlayan yapay sinir ağını ve yapay nöron ara bağlantılarının karmaşıklığını göstermektedir. Tekrarlı yapay sinir ağında bütün yapay nöronların tüm yönlerde diğer bütün nöronlara doğrudan bağlı olan ve tamamen tekrarlayan yapay bir ağ olması en temel topolojidir (Suzuki, 2011: 8).

Tekrarlı yapay sinir ağı modeli 1990 yılından bu yana, yapay sinir ağıları modelinin önemli bir parçasını oluşturmaktadır. Tekrarlamalı yapay sinir ağıları bütünüyle ya da belirli bir kısmıyla birbirine bağlanabileceği gibi ileri beslemeli bir ağ yapısında da olabilmektedir. Belirli bir kısmıyla birbirine bağlı olan yapay sinir ağlarında girdi veya çıktı katmanları belirgin iken bütünüyle birbirine bağlı olan ağlarda ise böyle bir belirginlik görülmemektedir (Medsker ve Jain, 2001: 12).

3.4.2. Öğrenme Kurallarına Göre Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağı uygulamalarında pek çok farklı öğrenme algoritması bulunmaktadır. Öğrenme algoritmaları problemin özelliği ve tercih edilen ağı yapısına göre değişiklik göstermektedir (Duman, 2016: 22). Eğitim süreci belli kurallar çerçevesinde gerçekleştirilen yapay sinir ağlarının öğrenmesi amaç ve ağ topolojisiyle doğrudan ilişkilendirilmektedir. Öğrenme kurallarının pek çoğu ilk öğrenme kuralı olan Hebb metodunun değişik varyasyonlarıdır. Günümüzde ise araştırmacılar insan öğrenmesine de benzeyen yeni öğrenme kuralları geliştirmektedir. İnsan öğrenmesine kıyasla oldukça sınırlı olan makine öğrenmesi kurallarının önemli birkaç türü aşağıdaki gibidir (Bayır, 2006: 30).

3.4.2.1. Hebb Öğrenim İlkesi

İlk ve en eski olarak bilinen öğrenme kuralıdır. Hebb kuralına göre; doğrudan bağlantılı olan iki nörondan birinde görülen değişim diğer nöronda da değişime neden olur ilkesinden hareketle etki altında kalan nörondaki değişimi öğrenmenin temeli olarak kabul etmektedir (Duman, 2016: 21).

3.4.2.2. Delta Öğrenim İlkesi

Hebb öğrenim ilkesinin temelini oluşturduğu delta öğrenim ilkesi günümüzde en sık kullanılan öğrenim türlerindendir. Öngörülen çıktı ile gerçekleşen çıktı arasında oluşan fark minimum değerini alana kadar bağlantı ağırlıklarını

güncellemeye dayanmaktadır (Duman, 2016:21). Yapay sinir ağı eğitilirken verilen girdi değerlerine karşılık elde edilen çıktı değeri ile gerçekleşen çıktı değeri arasındaki fark önceden belirlenmiş eşik değerinden yüksekse ağıın bağlantılarında güncelleme yapılmaktadır. Bağlantılar arasındaki güncelleme öğrenme katsayısı ile paralel olacak biçimde gerçekleştirilmektedir (Akbiğiç, 2011: 30).

3.4.2.3. Hopfield Öğrenim İlkesi

Hebb öğrenme ilkesine benzer bir yapıda olan hopfield öğrenme kuralı ayrıca bağlantı ağırlıklarının değişimini de belirtmektedir. Bağlantıların ağırlık değerleri öğrenme oranında artıp azalmaktadır (Yılmaz, 2012: 28). Hopfield öğrenme ilkesi çok döngülü ve geri yayımlı bir hesaplama sistemidir. Bu ağıda yer alan nöronların kendileri dışındaki tüm nöronlar ile bağlantılı olması yapay sinir ağıının kendi kendine geri bildirimi olmadığı anlamına gelmektedir. Hopfield öğrenme ilkesinde; tüm nöronlar hem girdi hem de çıktı görevi görmektedir, gizli nöron katmanı bulunmamaktadır, her nöron diğer tüm nöronlardan girdi almaktadır ve nöronlar kendilerine bağlı olmamaktadır (Örs, 2017: 25).

3.4.2.4. Kohonen Öğrenim İlkesi

Biyolojik sistem yapısından yola çıkarak geliştirilen bu öğrenme ilkesine aynı zamanda yarışmacı (competitive) öğrenme ilkesi de denilmektedir. Kohonen öğrenme ilkesinde işlem yapan eleman, ağırlıklarının belirlenmesi için yarışmaktadır. Tek seferde sadece bir işlemcinin yani galip gelen nöronun bağlantı ağırlıkları güncellenmektedir. Çıktı değeri en uygun olan işlemcinin kazanmasıyla kendisine komşu olan işlemcilerin ağırlıklarının da değiştirilmesine imkân sunmaktadır. Çıktı üretimini sadece kazanan işlemcinin üretmesi ve komşu işlemcileriyle birlikte ağırlıklarının değiştirilmesi mümkündür. Eğitim sürecinde komşu sayısında değişiklik olabilmekte ve en geniş komşu tanımlaması en dar komşu tanımlamasına indirilmektedir. Sonuçta girdinin desenini en iyi ifade eden eleman kazanan olarak tanımlanmaktadır (Bayır, 2006: 32).

3.4.2.5. Dereceli Azaltma (Gradient Descent) İlkesi

Dereceli azaltma ilkesinde de delta hatasının değiştirilebilmesi için transfer fonksiyonu türevi kullanılmaktadır. Ağırlık öğrenme oranının bir sabitle çarpılarak

değiştirilebilmektedir. Oldukça yavaş bir biçimde durağanlığı yakalasa da yaygın biçimde kullanılan bir ilkedir. Bu yapı için gerçekleştirilen araştırmalar farklı katmanlarda farklı öğrenme oranlarının kullanılmasının öğrenmeyi hızlandırdığını ve durağanlığın daha hızlı yakalandığını göstermektedir (Bayır, 2006: 31).

3.4.3. Öğrenme Algoritmalarına Göre Yapay Sinir Ağı Modelleri

3.4.3.1. Geri Yayılım (Backpropagation) Algoritması

Hatanın geriye doğru azaltılması hedeflendiği için geri yayılım algoritması olarak tanımlanan bu algoritma; ağ çıktısındaki hatanın dereceli azaltılması tekniği ile en düşük seviyeye indirilmeye çalışılmaktadır. Çok katmanlı ağ yapısına sahip sinir ağlarında geri yayılım algoritması tercih edilebilmektedir (Çetin, Uğur ve Bayzan, 2006: 2).

Geri yayılım tekniği; ileri beslemeyi ağ çıktısının belirlediği ve hatanın azaltılarak geri yayılması ile ağırlıkların güncellendiği geri besleme aşamalarından meydana gelmektedir. İleri besleme metodu ile elden edilen eğitim veri seti girdisi ağın giriş katmanını oluşturmaktadır ve bu katman girdileri saklayan nöronları içermektedir. Bu nedenle giriş katmanı ve veri seti girdi değerlerinin eşit sayıda olması gerekmektedir. Giriş katmanı nöronları girdi veri seti içeriğini doğrudan gizli katmana iletmektedir. Gizli katmanda yer alan tüm nöronlar; ağırlıklandırılan girdi değerine eşik değerini de ekleyerek toplam değer hesabı yapar ve bu değeri ilgili aktivasyon fonksiyonunda işleyip ya sonra gelen katmana ya da doğrudan çıktı katmanına iletmektedir. Katmanlar arası ağırlıklar ise genelde rasgele seçilmektedir. Çıkış katmanında yer alan tüm nöron girdilerinin net değeri, ağırlıklandırılan girdi değerine eşik değerin eklenmesi sonucu hesaplanmaktadır. Hesaplanan bu değer tekrar aktivasyon fonksiyonu kullanılarak işlenir ve çıktı değerleri bu şekilde belirlenmektedir. Elde edilen çıktı değeri ile beklenen çıktı değeri karşılaştırılır ve hata değeri elde edilir (Arı ve Berberler, 2017: 59).

3.4.3.2. Momentum Geri Yayılım Algoritması

Momentum geri yayılım algoritması yapısal açıdan geri yayımlı öğrenme ile benzerdir. Ağırlıklar güncellenirken alfa ve beta gibi sabit değerlere gereksinim

duyan momentum algoritmasının en önemli farkı ise ağırlıklar güncellenirken iki önceki ağırlık katsayısı değerlerinin kullanılmasıdır (Duman, 2016: 24).

3.4.3.3. Levenberg Marquardt Algoritması

Levenberg Marquardt (LM) algoritması en yaygın kullanılan optimizasyon algoritmalarından biridir. Pek çok çeşitli problemde basit gradyan iniş ve diğer eşlenik gradyan yöntemlerinden daha iyi performans göstermektedir (Ranganathan, 2004: 1).

Levenberg Marquardt algoritması doğrusal olmayan gerçek değerli fonksiyonların karelerinin toplamı olarak ifade edilen çok değişkenli bir fonksiyonun minimumunu belirleyen yinelemeli bir yöntemdir. Geniş bir bilimsel disiplinler yelpazesi tarafından yaygın olarak benimsenmiş doğrusal olmayan en küçük kareler problemleri için standart olarak kullanılan bir çözüm tekniği haline gelmiştir. Elde edilen çözüm doğru çözüme yakın olmadığında en dik iniş yöntemi gibi davranmaktadır. Mevcut çözüm doğruya en yakın değeri aldığı anda ise Gauss-Newton yöntemini benimsemektedir (Lourakis, 2005: 2).

3.4.3.4. Esnek Yayılım Algoritması

Esnek yayılım algoritması ilk kez 1993 yılında M. Riedmiller tarafından ileri beslemeli yapay sinir ağı tekniğinde kullanılmıştır. Esnek yayılım algoritması basit olarak; ağırlık adımlarında yer alan kısmi türev değerinin zararlı etkisini ortadan kaldırmayı hedeflemektedir. Böylece türev işaretleri ağırlıkların yönünü belirlemektedir (Saray, 2012: 47).

Standart eğim azaltma algoritmalarından çok daha hızlı bir yapıda olan esnek yayılım algoritması aynı zamanda negatif değerlerin saklanması da ihtiyaç duymamaktadır. Ard arda gelen iki iterasyon performansında fonksiyon ve türev işareti aynı ise güncelleme faktörü artırılırken farklı ise azaltılmakta ve türev sıfıra eşitken sabit kalmaktadır (Sağıroğlu, Beşdok ve Erler, 2003: 87).

3.4.3.5. Hızlı Yayılım Algoritması

Geri yayılım algoritmasının yavaş ve karmaşık olması nedeniyle hızlı ve sezgisel bir öğrenme tekniği geliştirilmiştir. Yöntem hızlı öğrenme sağlaması ve

gelecek çalışmalara temel oluşturacak olması nedeniyle önerilen bir teknik haline gelmiştir. Yöntemin sezgisel bir yapıda olması optimum çözümü üretememesine ve optimuma yakın bir çözüm sunabilmesine yol açmaktadır. Sezgisel algoritmalar genellikle tecrübe sonucu eğitilmiş ve tahmine dayalı kurallar içermektedir (Duman, 2016: 24).

3.4.3.6. Delta-Bar-Delta Algoritması

Bu algoritma ile çok katmanlı algılayıcıların bağlantı ağırlıkları yakınsama hızları arttırılabilmektedir. Sezgisel bir metot olan Delta-Bar-Delta algoritması tekniği ile yapılan deneysel çalışmalar; ağırlık uzayındaki her boyutun bütün hata düzeyleri açısından farklılık gösterebileceğini işaret etmektedir. Hata düzeyinde yaşanan değişimlerin açıklanabilmesi için ağda yer alan her bir bağlantının kendi öğrenme katsayısı olmalıdır. Her bağlantıya ayrı ayrı atanacak öğrenme katsayıları ve bu katsayılarda zaman içerisinde oluşan değişim yakınsama zamanını azaltarak serbestlik derecesini arttırmaktadır (Duman, 2016: 25).

3.4.3.7. Genişletilmiş Delta-Bar-Delta Algoritması

Genişletilmiş delta bar delta algoritması; sinir ağını eğitim aşamasında belirli bir anda çıkış hatasının hesaplanarak hatanın düzeltilmesi niteliğine sahiptir. Belirli bir zamanda gerçekleştirilen hata ölçümü eğer önceki adımda ölçülen hata değerinden büyükse yapay sinir ağırlıkları önceki değerine döndürülmektedir. Her işlem adımında hata testi yerine daha erken iyileştirme yapıldığından n farklı sıklıkta test edilmiş olmaktadır (Özkan, Kınacı ve Sağiroğlu, 2011: 33).

3.4.3.8. Genetik Algoritmalar

Günümüz karmaşık ve güç koşullarında problemlerin en hızlı ve basit biçimde çözümünü sağlayan tekniklerin kullanılması büyük avantajlar sağlamaktadır. Spesifik olarak soft hesaplamalar ve evrimsel algoritmalar bu teknikler içerisinde sivrilmiştir. Evrimsel algoritmalar sınıfı içerisinde yer alan genetik algoritma tekniğinin yeri bu yöntemler içerisinde oldukça önemlidir. Genetik algoritma metodu; fonksiyonların optimizasyonu, çizelgeleme, mekanik öğrenmesi, tasarım, hücre bazında üretim gibi alanlarda oldukça başarılı sonuçlar vermektedir. Klasik optimizasyon yöntemlerinden parametre kümesi yerine bu kümenin kodlanmış

içeriklerini kullanmasıyla farklılık göstermektedir. Çalışma sistematğinde olasılık kurallarının hâkim olduğı genetik algoritmalar sadece amaç fonksiyonuna gereksinim duymasının yanı sıra çözüm uzayının da tamamı yerine yalnızca bir kısmını taramaktadır. Kısmi tarama yapıyor olması nedeniyle daha etkin ve kısa sürede çözüme ulaşabilmektedirler (Elveren, 2009: 28).

3.4.4. Topolojilerine Göre Yapay Sinir Ağlarının Sınıflandırılması

Yapay sinir ağında yer alan nöronların bağlantı şekilleri, bağlantıların oluşturduğu katmanların sayısı ve bu katmanlar arasında yer alan veri iletiminin biçimi yapay sinir ağıının topolojisini belirlemektedir. Diğer bir ifadeyle ağ topolojisi; yapay sinir ağıını oluşturmak için kullanılan nöronların birleşme şeklidir. Yapay sinir ağıının sahip olduğı topoloji ağıın fonksiyonellik ve performansı gibi faktörler üzerinde önemli bir etkiye sahiptir. Ağ topolojisi belirlenirken çözülmek istenen problem yapısı önem taşımaktadır. Problemin çözümü için uygun topolojinin bilinmesi önemlidir. Günümüz gelişen teknolojisinde oldukça fazla sayıda topoloji kullanıldığı bilinirken bu topolojilerin sayısı ise net olarak bilinmemektedir (Bayır, 2006: 43).

Literatürde pek çok farklı ağ topolojisi bulunmakla birlikte yaygın biçimde kullanılan ağ topolojileri içerisinde katmanlı sinir ağları, radyal tabanlı sinir ağları, vektör yapay sinir ağları, olasılık tabanlı yapay sinir ağları gibi modeller sayılmaktadır (Duman, 2016: 26).

3.4.4.1. Tek Katmanlı İleri Beslemeli Yapay Sinir Ağları


Tek katmanlı ileri yayılımlı yapay sinir ağları, bir veya daha fazla nöronu bulunan bir girdi ve çıktı katmanı içermektedir. Girdi katmanında yer alan her bir nöron çıkış katmanındaki tüm nöronlar ile bağlantılıdır. Nöronların girdi değerleri bağlantı ağırlıkları ile çarpılarak toplanmaktadır. Toplanan bu değerin belirli bir eşik değerini aşması durumunda nöron bir çıktı üretmektedir (Bayır, 2006: 45).

Sadece girdi ve çıktı katmanları bulunan ara katmanları bulunmayan tek katmanlı yapay sinir ağı yapısında her ağıın bir veya daha fazla girdisi bulunmaktadır. Tek katmanı bulunan algılayıcılarda oluşan çıktı doğrusal bir fonksiyondur. Başka bir ifadeyle ağı sunulan örnek veriler iki sınıf arasında ayrıştırılmaktadır. Ağ çıktısı girdi değerleri ve nöron ağırlıklarının çarpılarak eşik değere eklenmesi sonucu elde

edilmektedir. Girdi verisi aktivasyon fonksiyonunda işlenerek ağ çıktısı hesaplanmaktadır. Tek katmanlı yapay sinir ağları doğrusal problem çözümlerinde başarı gösterirken, doğrusal olmayan problemlerin çözümlerinde ise yeterli bulunmamaktadır (Duman, 2016: 26).

Tek katmanlı bir yapay sinir ağında nöronlar tabakalar şeklinde düzenlenmekte ve en basit şekliyle katmanlı bir ağda sinyalin direkt olarak giriş katmanından çıkış katmanına aktarıldığı bir yapı bulunmaktadır. Bu veri akışı aksi yönde olamamaktadır. Şekil 11 ile görülen ileri beslemeli tek katmanlı yapay sinir ağında; bu yapının tek katmanlı yapay sinir ağı olarak gösterilmesinin nedeni girdi katmanında herhangi bir hesaplama yapılmıyor olmasıdır (Haykin, 1998: 21).

Şekil 11: Tek Katmanlı İleri Beslemeli Yapay Sinir Ağı




Kaynak: Haykin, 1998: 21'den alınarak tekrar düzenlenmiştir.

3.4.4.2. Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı

İleri beslemeli yapay sinir ağının diğer modeli ise ağın girdi veya çıktılarında direkt olarak görülmeyen ancak bir ya da daha fazla gizli katman veya nöronların yer aldığı çok katmanlı modeldir. Ağ içerisinde yer alan gizli nöron fonksiyonu girdi veya çıktı katmanı arasında faydalı müdahalelerde bulunmaktadır. Yapay sinir ağında bir ya da daha fazla gizli katman bulunması yüksek sıralı istatistikler elde edilmesine imkân sunar. Yapay sinir ağının giriş katmanı ilk gizli katmanda yer alan

nöronlara etki eden giriş sinyallerine ait aktivasyon fonksiyonundaki verileri ulaştırmaktadır. Üçüncü katman, ikinci katmandaki çıkış sinyallerini girdi olarak kullanırken bu çıkış sinyalleri ağı geri kalanı için de kullanılmaktadır. Standart biçimde yapay sinir ağında yer alan her katman yalnızca önceki katmanın çıkış sinyalini algılamaktadır. Yapay sinir ağının son katmanında yer alan nöronlar çıkış sinyalleri, yapay sinir ağının giriş katmanının kaynak düğümleri aktivasyon modelinin genel cevabını oluşturmaktadır (Haykin, 1998: 22).

Şekil 12: Çok Katmanlı İleri Beslemeli Yapay Sinir Ağı




Kaynak: Haykin, 1998: 21 kaynağından alınarak yeniden düzenlenmiştir.

Şekil 12’de gösterilen yapay sinir ağının temel bileşeni nöronlar bir araya gelerek katmanları meydana getirmektedir. Katmanların birbirleriyle olan bağlanma şekilleri ise farklı ağ topolojilerini oluşturmaktadır. Temel anlamda girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç farklı nöron türü bulunmaktadır. Giriş katmanında yer alan nöronlar dışardan yapay sinir ağına gelen bilgileri girdi katmanına iletmektedir. Bilginin dışarıya iletildiği son katman ise çıktı katmanıdır. Girdi ve çıktı katmanları arasında her zaman olmasa da gizli katmanlar bulunmaktadır. Nöronlara gelen bilginin net ağırlığının hesaplanmasında farklı fonksiyonlar kullanılabilir. Ağırlıklı toplam fonksiyonu bu fonksiyonlara örnek olarak verilebilir. Ağırlıklı toplam fonksiyonunda her gelen girdi ile ağırlığı çarpılarak kümülatif toplamı bulunmaktadır. Bu şekilde nöronlara ulaştırılan net girdinin ağırlığı hesaplanmış olmaktadır (Çavuşoğlu, 2021: 53).

3.4.4.3. Tekrarlı (Recurrent) Yapay Sinir Ağı

İleri beslemeli yapay sinir ağından en az bir geri besleme döngüsü ile ayırt edilebilen tekrarlı yapay sinir ağında; her nöronun çıkış sinyali geriye kalan bütün nöron girişlerini geri besleyen bir tek nöron katmanından oluşabilir. Ağ içerisinde kendine geri bildirim döngüsü bulunmamaktadır. Bir nöron çıkışının kendi girdisini geri beslemesi ise geribildirim kendinden olduğu durumda gerçekleşmektedir. Şekil 13 ile gösterilen yapay sinir ağında gizli bir nöron bulunmamaktadır (Haykin, 1998: 23).


Şekil 13: Tekrarlı (Recurrent) ve Gizli Katmanın Bulunmadığı Yapay Sinir Ağı



Kaynak: Haykin, 1998: 23 kaynağından alınarak tekrar düzenlenmiştir.

Şekil 14 ile gösterilen yapay sinir ağında ise gizli katmanlı ve tekrarlayan yapay sinir ağıdır. Gizli katmanlı tekrarlı yapay sinir ağı yapısında yer alan geri besleme hem gizli nöronlardan hem de çıktı nöronlarından kaynaklanmaktadır. Şekil 13 ve 14'te gösterilen tekrarlı yapay sinir ağlarındaki geri besleme yapay sinir ağının hem öğrenme hem de performansını oldukça etkilemektedir (Haykin, 1998: 23).

Şekil 14: Gizli Katmanlı Tekrarlı (Recurrent) Yapay Sinir Ağı



Kaynak: Haykin, 1998: 23.

3.5. Yapay Sinir Ağlarının Kullanıldıkları Yerler

Yapay sinir ağları, eksik veri seti üzerinde işlem yapabiliyor olması ve normal dağılmayan veriler üzerinde problem çözebiliyor olması gibi yetenekleri dolayısıyla günümüzde oldukça yoğun biçimde tercih edilen bir teknik özelliğindedir. Doğrusal veri içermeyen, birden fazla boyutu olan, karmaşık, eksik veriler içeren ve hata payı oldukça yüksek veri setleriyle oluşturulan problemlerin çözümünde yapay sinir ağı uygulamaları oldukça başarılı sonuçlar sunmaktadır. Bu hedefler ile geliştirilen ağlar; probabilistik fonksiyon kestirimleri, sınıflandırma, örüntü tanımlama, zaman serisi analizi, sinyal filtreleme, veri sıkıştırma, doğrusal olmayan sinyal işleme, doğrusal olmayan sistem modelleme, optimizasyon ve doğrusal olmayan kontroller gibi pek çok şartıda sağlamaktadır. Pratik olmayan bu uygulamaların dışında yapay sinir ağları ayrıca ekonomi, mühendislik ve tıp gibi pek çok alanda da sıklıkla tercih edilen bir tekniktir. Gerçekleştirilen uygulama alanlarında bazıları (Çot, 2019: 33);

- Finansal Veriler: Ekonomik tahminler, finans kurumlarının iflas ve kredi kartı sahtekârlık veri tahmini ve yönetilmesi, risk analizleri yapay sinir ağı tekniğiyle değerlendirilmektedir.
- Arıza Tespiti: Bir sistem, makine veya sıralı işlemde gerçek zamanda oluşabilecek aksaklıkların saptanması sağlanabilmektedir.

- Sağlık Uygulamaları: Organ nakil zamanı optimizasyonu, kanserli hücre tespiti, EEG ve ECG gibi tıbbi sinyallerin çözülmesi gibi konularda yapay sinir ağı tekniği kullanılmaktadır.
- Savunma Sanayi Uygulamaları: Savunma sanayii sistemlerinin otomasyonu, nesne görüntüleme ve ayırıştırma, gürültü engelleme gibi alanlarda kullanılmaktadır.
- Haberleşme Uygulamaları: Görüntü verilerinin sıkıştırılması, otomatik veri sunma sistemleri, eş zamanlı çeviri yapmak gibi alanlarda kullanılmaktadır.
- Üretim Uygulamaları: Ürün ve kalite analizi, ürün tasarımının optimizasyon kontrolü, üretim planlama ve üretim sistemlerinin optimizasyon gibi alanlarda uygulanmaktadır.

Yapay sinir ağlarının işlevsel olarak kullanım alanları ise (Jain, Mao ve Mohiuddin, 1996):

- Veri Tahmini: Yapay sinir ağına verilen bilgiler kullanılarak geleceğe yönelik veri tahmini yapılmaktadır.
- Sınıflandırma: Yapay sinir ağına verilen bilgiler kategorize edilebilmektedir.
- Veri Tamamlama: Yapay sinir ağında işlenen verilerden hatalı olanların tespit edilerek eksik veriler tamamlanabilmektedir.
- Veri Süzme: Büyük veri yığınları içerisinde kullanışlı bilgileri belirleyebilmektedir.
- Veri Tanıma ve Eşleştirme: Farklı biçimdeki verilerin tanımlanarak; eksik, karmaşık ve belirsizlikler içeren eşleştirme ve tanıma işlevleri yapılabilmektedir.
- Saptama: Varolan bir sistemin olumsuz tarafları ve sorunları belirlenebilmektedir.
- Yorum Geliştirme: Belirli bir olayla ilgili gerçekleşen bütün örnekler üzerinden eğitim süreci sonrasında yorumlama yapabilmektedir.

3.6. Yapay Sinir Ağlarının Olumlu ve Olumsuz Özellikleri

3.6.1. Yapay Sinir Ağlarının Olumlu Özellikleri

Yapay sinir ağlarının temel fonksiyonu öğrenme özelliği sayesinde makine öğrenmesi yapmaktadır. Örnek veri setinden öğrenilen bilgiler benzer olaylar karşısında düzgün karar almaya yardımcı olmaktadır. Bilgi işleme süreçlerinin klasik programlamadan ağına tamamına yayılarak saklanması nedeniyle farklılık göstermektedir. Veriler ağına tamamına yayılmış halde olduklarından bazı nöronların işlevsiz kalması herhangi bir bilgi kaybı oluşturmamaktadır. Örnekler kullanılarak gerçekleştirilen öğrenme sayesinde ağ eğitilir ve hedeflenen çıktıya uygun biçimde eğitim sürecinin gerçekleşmesi sağlanmaktadır. Yapay sinir ağı eğitimi için gönderilen veri ağı tamamen temsil ediyorsa çıktı başarısı artmaktadır. Yapay sinir ağları daha önce karşılaşılmayan veriler üzerinden de sonuç üretebildikleri için algılama süreçlerinde de sıklıkla tercih edilmektedirler. Örüntüleri tanımlama ve gruplandırma işlevini gerçekleştirebilen yapay sinir ağları, eğitim verisi üzerinden örüntü tanımlayarak mevcut örüntülerle ilişkilendirme yapabilmektedir. Eksik verilerin tamamlanması konusunda oldukça önemli olan örüntü tanımlama fonksiyonu sayesinde eksik veri seti yapay sinir ağı tarafından tamamlanabilmektedir (Tolon, 2008: 252).

Kendi kendine öğrenebilme ve organizasyon yetenekleri olan yapay sinir ağları eksik bilgiyle çalışabildikleri için eğitim süreci sonundaki girdi verisi eksik değer içerse dahi çıktı üretebilmektedir. Ancak eksik bilginin önemi yüksekse tahmin doğrulunda düşüş gözlemlenmektedir. Sahip oldukları hata toleransı nedeniyle ağ içerisinde yer alan bazı hücre fonksiyonları kaybolursa da yapay sinir ağı çalışmaya devam edebilmektedir. Dağınık bellek yapıları olan yapay sinir ağlarında, nöronlardaki bağlantı ve ağırlık dereceleri ağdaki bilgiyi göstermektedir. Sınırsız sayıdaki değişken ve parametre ile çalışma yeterliliği bulunan yapay sinir ağları karmaşık problem çözümlerinde oldukça büyük başarı göstermektedir (Şerbetli, 2008: 98).

3.6.2. Yapay Sinir Ağlarının Olumsuz Özellikleri

Yapay sinir ağlarının etkin biçimde çalışabilmesi için paralel işlemcilere gereksinimi vardır, bu nedenle donanım yapısına bağımlılık göstermektedir. Eğitim

ve öğrenme de kullanılacak veri sayısının belirlenmesi için nihai bir kriter bulunmamaktadır. Problemin çözümü için gerekli olan veri sayısı değişebilmektedir. Probleme uygun ağ yapısı belirken sabit bir kural bulunmamakta ve deneme yanılma ile ağ topolojisi belirlenmektedir. Yapay sinir ağlarında öğrenme katsayısı, nöron ve katman sayısı gibi ağ parametrelerinin belirlenmesi için standart bir kural bulunmamaktadır. Bu gibi değerler belirlenirken herhangi bir standart bulunmuyor olması her problem için farklı bir yaklaşım kullanılmasına neden olmaktadır. Yapay sinir ağları sayısal verilerle çalışabildiklerinden problem verilere ağa tanıtılmadan önce sayısal değerlere dönüştürülmelidir. Yapay sinir ağının eğitilmesi uzun zaman alabileceği için ekonomik maliyeti de yüksektir (Duman, 2016: 34).

3.7. Yapay Sinir Ağının Tasarımı

Yapay sinir ağı modeli oluşturulurken takip edilmesi gereken en temel kurallar (Delvin vd. 1990: 65);

- İlk olarak sistem çıktısının ne olacağı belirlenmelidir.
- Elde edilmek istenen çıktı üzerinde etkisi olabilecek değerler yapay sinir ağının girdisi olarak belirlenmelidir.
- Belirlenen girdi değerleri ile bir veri seti oluşturularak eğitim ve test verisi ayrılmalı ve yapay sinir ağının kullanabileceği biçimde dönüştürülmelidir.
- Kullanılacak olan yapay sinir ağının özellikleri (ağ topolojisi) belirlenmelidir.
- Yapay sinir ağında kullanılacak olan öğrenme algoritması belirlenmelidir.
- Yapay sinir ağının eğitimi ve testi yapılmalıdır.
- İstenilen başarı düzeyine ulaşana kadar bu adımlar tekrar edilmelidir.

Yapay sinir ağı tekniğinde elde edilmek istenen çözüme göre ağ yapısı farklılaşmaktadır. Bu nedenle yapay sinir ağının kullanım amacına göre istenen problemin çözümü de ağın doğru tercih edilmesiyle birebir ilgilidir. Yapay sinir ağı çeşitlerinin kullanımı; tahmin, sınıflandırma ve veri ilişkilendirme olacak şekilde üç farklı gruba ayrılmaktadır (Yakut, 2012: 97).

Tablo 5: Yapay Sinir Ağı Türlerinin Sınıflandırılması

Kullanış Amacı	Yapay Sinir Ağı Çeşidi	Kullanım Alanları
Tahmin	Çok katmanlı ağ	Ağ girdileri kullanılarak, çıktı değerinin tahmin edilmesi
Sınıflandırma	LVQ ART Counterpropagation ağı Olasılık sinir ağı	Girdi değerlerin ait olduğu sınıfların belirlenmesi
Veri İlişkilendirme	Hopfield Boltzmann makinesi Çift Yönlü İlişkisel Hafıza	Girdi değerlerde yer alan eksik değerlerin tespit edilip tamamlanması ve hatalı verilerin tespiti

Kaynak: Yakut, 2012: 97'den alınarak yeniden düzenlenmiştir.

3.7.1. Öğrenme Algoritmasının Belirlenmesi

Yapay sinir ağının başarılı sonuçlar üretmesini etkileyen en önemli faktörlerin başında ağ mimarisinin belirlenmesi gelmektedir. Problemin türüne uygun yapay sinir ağı topolojisinin seçilebilmesi, ağda kullanılacak olan öğrenme algoritmasına göre değişiklik göstermektedir. Pek çok yapay sinir ağı yapısı bir tek öğrenme algoritmasıyla çalışabilmektedir. Bu nedenle öğrenme algoritması seçildiğinde yapay sinir ağı topolojisi de belirlenmiş olmaktadır (Bayır, 2006: 83).

Tablo 6: Öğrenme Algoritmalarının Kullanım Türleri

Uygulama Alanı	Yapay Sinir Ağı
Öngörü	Geri beslemeli Delta-bar delta Genelleştirilmiş delta-bar-delta Rassal tarama
Sınıflandırma	LVQ Olasılıklı yapay sinir ağı Counterpropagation ağı
Veri ilişkilendirme	Hopfield Boltzman
Veri kavramlaştırma	ART SOM

Kaynak: Yakut, 2012: 98'den alınarak yeniden düzenlenmiştir.

3.7.2. Yapay Sinir Ağının Gizli Katman Sayısının Tespit Edilmesi

Yapay sinir ağında yer alan katman sayısı ve bu katmanların her birinde yer alan nöronların sayısı yapay sinir ağının karmaşıklığını belirtmektedir. Katman ve nöron sayısındaki artış yapay sinir ağının öğrenme kapasitesini artırırken yakınsama süresini de beraberinde arttırmaktadır. Bu durum yapay sinir ağının genelleme yeteneğini azaltırken ağın ezberleme düzeyinin de artmasına neden olmaktadır. Gerekli olandan daha az sayıda katman ve nöron kullanımı ise veri örüntülerinin eksik öğrenilmesine yol açmaktadır. Genellikle pek çok problem çözümünde iki veya üç katmanlı yapay sinir ağları daha iyi sonuçlar üretmektedir. Katman ve nöron sayısı belirlemenin en iyi yöntemi birkaç deneme ile ağ performansının ölçülüp en uygun katman sayısına karar verilmesidir (Bayır, 2006: 84).

3.7.3. Katmanlarda Yer Alan İşlem Eleman Sayısının Belirlenmesi

Yapay sinir ağının gizli katmanında yer alacak işlem elemanı sayısının belirlenmesi için standart bir prosedür bulunmamakla birlikte genellikle deneme-hata oranı inceleme yöntemine başvurulmaktadır. Her farklı deneme sonrasında yapay sinir ağının ürettiği hata dikkate alınarak optimum işlem elemanı sayısı belirlenmektedir. Optimum eleman sayısının belirlenebilmesi için yapay sinir ağının büyütülme veya budanma olarak ifade edilen fonksiyonların yerine getirilmesi gerekmektedir. Bu süreç; küçük bir ağ yapısından yola çıkılarak eleman sayısı arttırılmaktadır. Yapay sinir ağında hata oranının arttığı aşamada gizli katman için uygun eleman sayısına erişildiği anlaşılmaktadır. Diğer metotta ise tam tersi olarak; geniş bir ağ ile eğitim sürecine başlanmaktadır. Yapay sinir ağının genelleme yeterliliğinin düşüşe geçmesine kadar ağ küçültülür. Bu şekilde yine hata oranları kontrol edilerek optimum işlem elemanı sayısı belirlenmektedir (Öztemel, 2003: 105).

3.7.4. Yapay Sinir Ağının Parametre Seçimi

Yapay sinir ağı teknoloji kullanılarak bir model geliştirilirken önemli konulardan biri ağ parametrelerinin belirlenmesidir. Bu parametre seçimi sürecine; başlangıç ağırlıklarının saptanması, momentum ve öğrenme katsayılarının tespiti, toplam ve aktivasyon fonksiyonlarının seçilmesi aşamalarından meydana gelmektedir. Bu aşamaların uygulama adımları (Öztemel, 2003: 81):

- **Yapay Sinir Ağına Başlangıç Ağırlık Değerlerinin Atanması:** Yapay sinir ağı yapısı eğitim sürecine başladığında bağlantı ağırlıklarının belirlenmiş olması gerekmektedir. Yapay sinir ağının öğrenmeye başladığı nokta başlangıç ağırlığı olarak tanımlanmaktadır. Eğer başlangıç ağırlığı geniş bir aralıkta belirlenirse; ağ yerel noktalar arasında salınımına uğrayacaktır. Eğer başlangıç ağırlığı dar bir aralıkta belirlenirse; ağın öğrenme hızı daha düşük olacaktır. Bu değer genellikle -1 ile +1 aralığında kalacak biçimde rassal olarak belirlenmektedir.
- **Yapay Sinir Ağının Öğrenme Oranının Belirlenmesi:** Yapay sinir ağında öğrenme oranı; ağın hangi hızda öğrendiği anlamına gelmektedir. Ağırlıkların belirlenmesi ve ağırlık değerlerindeki net değişimin hangi oranda yenileme hesabına katılacağı bu orana bağlıdır. Öğrenme oranının küçük seçilmesi süreci ağırlaştırırken büyük değerler verilen öğrenme oranları ise ağın yerel çözümler üzerinde sabitlenmesine neden olacaktır. Bu nedenlerle öğrenme oranı genellikle 0 ile 1 aralığında değerler almaktadır.
- **Yapay Sinir Ağı Momentum Katsayısının Tespiti:** Yapay sinir ağının eğitim süreci başlamadan önce belirlenmesi gereken bir diğer parametre ise momentum katsayısıdır. Momentum katsayı değeri; önceki iterasyon sonucu ağırlık değerlerinde meydana gelen net değişim miktarının ne ölçüde yeni değişim miktarına ekleneceğini belirtmektedir. Momentum katsayısının belirlenirken genellikle 0.6-0.8 aralığında bir değer almaktadır.
- **Yapay Sinir Ağı Aktivasyon Fonksiyonunun Tespiti:** Yapay sinir ağında kullanılacak aktivasyon fonksiyonu belirlenirken bazı standart kullanım örnekleri bulunmaktadır. Eğer problemin ortalama davranışı öğrenilmek isteniyorsa sigmoid fonksiyonu, öngörü problemlerinde olduğu gibi ortalamadan sapmaların belirlenmesi isteniyorsa hiperbolik tanjant fonksiyonu önerilmektedir. Ancak sayılardan farklı aktivasyon fonksiyonlarının yapay sinir ağının performansına belirgin bir etkisinin olup olmadığı net olarak ifade edilememektedir. Liretatürde sıklıkla sigmoid fonksiyonun tercih edildiği gözlemlenmektedir.

- **Yapay Sinir Ağı Verilerinin Normalleştirilmesi:** Veri setinde uç değerlerin bulunması optimizasyonu olumsuz etkileyeceğinden verilerin yapay sinir ağına sunulmadan önce normalize edilmesi gerekmektedir. Normalizasyonun bir diğer sebebi ise aktivasyon fonksiyonunun $[0,1]$ veya $[-1,1]$ gibi aralıklar dışında duyarlılığının artmasıdır. Bu nedenle normalizasyon işlemi yapılmazsa önemli miktarda veri kaybedilebilmektedir.
- **Yapay Sinir Ağı Eğitim ve Test Verisinin Belirlenmesi:** Eğitim verisi yapay sinir ağının geliştirilmesi, test verisi ise model performansının değerlendirilmesi için kullanılmaktadır. Literatürde genellikle %90 eğitim %10 test, %80 eğitim %20 test, %70 eğitim %30 test olarak ayrılmaktadır.
- **Yapay Sinir Ağının Eğitilmesi ve Test Edilmesi:** Eğitim ve test olmak üzere iki aşamada gerçekleşen yapay sinir ağı öğrenmesi için ilk aşamada eğitim verisi ağı sunulur ve optimum ağırlıklar tespit edilir. Yapay sinir ağından elde edilen çıktı değeri hedeflenen değere ulaştığında süreç sabitlenerek test aşaması başlatılmaktadır. Test aşaması; yapay sinir ağının önceden görmediği örnekler üzerindeki davranışlarının gözlemlenmesi aşamasıdır. Test ve eğitim süreci hataları arasındaki fark kabul edilebilir ise yapay sinir ağı kullanıma hazır olarak kabul edilmektedir.
- **Eğitimin Durdurulması:** Eğitim sürecinin tamamlanacağı aşama hem yapay sinir ağının genelleştirme yeteneğini etkileyebilmekte hem de aşırı eğitim durumunda ezberlemeye yol açmaktadır. Bu nedenle eğitim sürecinin optimum aşamada belirlenmesi ağın başarı oranını da yükseltmektedir. Eğitimin bitirilmesi için üç farklı metot bulunmaktadır. Birinci metot; önceden belirlenen iterasyon sayısına ulaşıldığında eğitim sonlandırılır. İkinci metot; tolere edilebilir bir hata seviyesi belirlenerek eğitime başlanır ve bu hataya erişildiğinde eğitim durur. Son metot ise; çapraz geçerlilik olarak belirlenen onaylama setinde hata oranı yükselmeye başladığında eğitim durdurulmaktadır.

- Yapay Sinir Ağı'nın Performans Kriterinin Tespiti: Yapay sinir ağı teknolojisinde öngörü verisinin değerlendirilebilmesi için performans kriteri gerekmektedir. Performans kriteri; yapay sinir ağı'nın veriler arasındaki örüntüyü ne kadar öğrendiğini ölçmektedir. Yapay sinir ağı için kullanılan performans kriterleri aşağıdaki gibidir (Çot, 2019:59):

1. Hata Kareler Ortalaması (Mean Squared Error-MSE) (Çot, 2019:59 kaynağından düzenlenerek kullanılmıştır):

$$HKO = \frac{1}{n} \sum_{i=1}^n (t_i - g_i)^2 = \frac{1}{n} \sum_{i=1}^n e_i^2$$

t_i : i. birimde gerçekleşen tahmin değeri

g_i : i. birimdeki gerçek değer

e_i : tahmin tahası.

2. Hata Karaler Toplamı (Sum Squared Error-SSE) (Nainggolan et. al. 2019: 3 kaynağından düzenlenerek kullanılmıştır);

$$HKT = \frac{1}{n} \sum_{i=1}^n (t_i - g_i)^2 = \sum_{i=1}^n e_i^2$$

t_i : i. birimde gerçekleşen tahmin değeri

g_i : i. birimdeki gerçek değer

e_i : tahmin tahası

3. Ortalama Mutlak Hata Yüzdesi (Mean Absolute Percentage Error-MAPE) (Khair et. al. 2017:2 kaynağından düzenlenerek kullanılmıştır);

$$OMHY = 100 * \frac{\sum_{i=1}^n (t_i - g_i)^2}{n \cdot t_i}$$

t_i : i. birimde gerçekleşen tahmin değeri

g_i : i. birimdeki gerçek değer

e_t : tahmin tahasını göstermektedir.

3.8.Yapay Sinir Ağlarının Tahminlemede Kullanımı

Yapay sinir ağları sınıflandırma, modelleme ve tahmin gibi pek çok alanda tercih edilen bir tekniktir. Yapay sinir ağı tekniği karmaşık sistemlerin modellenmesi, parametre tahmini, alana özgü parametrelerin tahmini gibi konularda sıklıkla tercih edilmektedir. Co ve Boosarawongse (2007) çalışmalarında zaman serisi ve yapay sinir ağı tekniklerini kullanarak Tayland'ın pirinç ihracatını tahmin etmişlerdir. Ballı (2014) çalışmasında şarküteri ürünlerinin talep tahminini yapay sinir ağı tekniği kullanarak gerçekleştirmiştir. Kutlu ve Badur (2009) çalışmalarında borsa endeksi tahminini yapay sinir ağı ve zaman serisi tekniklerini kullanarak karşılaştırmışlardır. Polat (2009) çalışmasında Türkiye'nin aylık toplam ithalat ve ihracat verilerini yapay sinir ağı ve zaman serisi tekniklerini kullanarak tahmin etmişlerdir. Tablo 7 ile yapay sinir ağı ve diğer klasik istatistiksel tahmin tekniklerinin karşılaştırıldığı çalışmalar ile hangi tekniğin daha başarılı sonuçlar verdiği özetlenmiştir.

Tablo 7: Literatür Taraması

Yazar (Yıl)	Çalışma Amacı	Başarılı Yöntem
Subaşı ve Erdem(2021)	Nanoakışkanların özgül ısı tahmininde Yapay Sinir Ağı tahmini ile korelasyon karşılaştırması	YSA
Çelik ve Köleoğlu (2022)	Türkiye'de korunga üretim miktarının tahminlenmesinde Yapay Sinir Ağı ve Trend Analizi karşılaştırması	YSA
Han vd. (2022)	Otomobil satışlarının tahminlenmesinde Yapay Sinir Ağı ve Holt Winters yönteminin karşılaştırılması.	YSA
Özmen-Akyol (2022)	Meme kanseri tipi tahmini için yapay sinir ağı ve lojistik regresyon modellerinin karşılaştırılması	YSA
Şahin ve Yalçinkaya (2021)	Polimer maddenin aşınmasını etkileyen faktörlerin belirlenmesi için yapay sinir ağı, taguchi yaklaşımı ve regresyon analizi kullanılmıştır.	Taguchi
Özkan, Sarer-Yürekli ve Suner (2021)	Diyabet tanısının tahminlenmesi için Naïve Bayes, Bayes ağları, rastgele orman, karar ağaçları, destek vektör makinaları, k-en yakın komşuluk, yapay sinir ağları ve çokterimli lojistik regresyon yöntemleri kullanılmıştır.	Rasgele orman algoritması

Tabar, Başara ve Şişman (2021)	Konut değerlendirme tahmini için regresyon ve yapay sinir ağı teknikleri kullanılmıştır.	YSA
Ünvan ve Ergenç (2022)	BIST 100 indeks tahmininde regresyon ve yapay sinir ağı teknikleri karşılaştırılmıştır.	YSA
Cansız, Erginer ve Doğru (2021)	Trafik kazası sayılarının tahmininde regresyon ve yapay sinir ağı teknikleri incelenmiştir.	YSA
Solmaz, Tiren ve Özkaya (2021)	Kalp hastalıklarının tespitinde destek vektör makineleri, yapay sinir ağları ve k-en yakın komşu yöntemleri karşılaştırılmıştır.	YSA
Çoban ve Demir (2021)	Gıda firması için talep tahmininde destek vektör regresyonu ve yapay sinir ağı teknikleri karşılaştırılmıştır.	YSA
Kayakuş ve Terzioğlu (2021)	Emeklilik fonu varlık değeri tahmininde regresyon ve yapay sinir ağı teknikleri karşılaştırılmıştır.	YSA
Gündoğdu (2021)	Egzersiz öncesi ve sonrası durumun sınıflandırılması için destek vektör makineleri ve yapay sinir ağı tekniği karşılaştırılmıştır.	YSA
Yörübulut vd. (2020)	Beton basıncının dayanıklılık tahmininde yapay sinir ağı ve regresyon analizi teknikleri karşılaştırılmıştır	YSA ve regresyon yakın sonuçlar vermiştir.
Sönmez ve Zengin (2019)	Gıda talep tahmini için regresyon ve yapay sinir ağı tekniklerinin karşılaştırılması	YSA
Can ve Gerşil (2018)	Pamuk fiyatlarının tahmininde zaman serisi ve yapay sinir ağı tekniklerinin karşılaştırılması	YSA
Keskin (2020)	Yağış verilerinin tahmininde yapay sinir ağı, regresyon ve zaman serisi analizi yapılmıştır.	YSA
Aditian, Kubota, Shinohara (2018)	Heyelan duyarlılık Değerlendirmesi için lojistik regresyon ve yapay sinir ağı teknikleri karşılaştırılmıştır.	YSA
Zhang, Liu, Rao, Li ve Zhao (2020)	Havalandırma oranının tasarım başarısına etkisinin tespit edilmesinde genetik algoritma, yapay sinir ağı, çok değişkenli regresyon analizi ve bulanık mantık denetleyicisi performansları karşılaştırılmıştır	Genetik Algoritma
Hassanipour vd. (2019)	Travmatik hastalarda sonuç tahmini için yapay sinir ağı ve regresyon modelleri karşılaştırılmıştır.	YSA
Zhang vd.(2018)	Rezervuar opsiyonlarının modellenmesinde yapay sinir ağı, destek vektör makineleri ve derin öğrenme algoritmalarını karşılaştırmışlardır.	YSA
Hosseinzadeh vd.	Katı atıklardan besin geri kazanımı oranlarının	YSA

(2020)	tahmininde yapay sinir ağı ve regresyon yöntemlerini karşılaştırmışlardır.	
Shams vd. (2020)	Havadaki CO konsantrasyonunu tahmin etmek için yapay sinir ağı ve regresyon teknikleri karşılaştırıldı.	YSA
Kavuncuoğlu vd. (2018)	Antimikrobiyal aktivite tahmini için yapay sinir ağı ve regresyon teknikleri karşılaştırılmıştır.	YSA
Nhu vd (2020)	Heyelan duyarlılık haritası oluşturulmasında Lojistik Model Ağacının Karşılaştırılması, Lojistik Regresyon, Naif Bayes Ağacı, Yapay Sinir Ağı ve Destek Vektörü Makine Algoritmaları karşılaştırılmıştır	Lojistik model ağacı
Mohammadi vd. (2021)	Covid-19 enfekte kişilerin sınıflandırılması için lojistik regresyon ve yapay sinir ağı teknikleri karşılaştırılmıştır.	YSA ve regresyon teknikleri benzer sonuçlar vermiştir.
Khosravi vd (2018)	Bir rüzgâr türbininin rüzgâr hızını, rüzgâr yönünü ve çıkış gücünü tahmin etmek için yapay sinir ağı, destek vektör makineleri ve anfis yöntemleri karşılaştırılmıştır.	Destek vektör makineleri
Polykretis ve Chalkias (2018).	Heyelan duyarlılık değerlendirmesi için lojistik regresyon ve yapay sinir ağı teknikleri karşılaştırılmıştır.	Lojistik regresyon
Abrougui (2019)	Toprak işleme sistemlerinin toprak üzerindeki etkisinin tahmin edilmesinde yapay sinir ağı lojistik regresyon teknikleri karşılaştırılmıştır.	YSA
Al-Bayati (2019)	Duygu analizi için naive bayes, maksimum entropi ve destek vektör makinesi teknikleri karşılaştırmıştır.	Destek vektör makinesi
Karaçor (2017)	Mali piyasa veri tahmininde yapay sinir ağı ve destek vektör makineleri teknikleri karşılaştırılmıştır.	YSA
Karakuş (2015)	Stok market modellemesi için regresyon ve yapay sinir ağı teknikleri kullanılmıştır.	YSA
Yasin (2013)	Kısa dönem elektrik talep tahmini için yapay sinir ağı ve destek vektör makineleri teknikleri karşılaştırılmıştır.	YSA
Almahmud (2019)	Malzeme satış tahmini için zaman serisi ve yapay sinir ağları teknikleri karşılaştırılmıştır.	YSA
Aşıkgil (2012)	İnşaat projeleri maliyet tahmini için regresyon, vaka bazlı çözümleme ve yapay sinir ağı teknikleri	Vaka bazlı çözümleme

	karşılaştırılmıştır.	
Özkan (2019)	Yer sarsıntı tahmininde regresyon ve yapay sinir ağı tekniği karşılaştırılmıştır.	YSA
Sözgen (2009)	İhale teklif tahmini için regresyon analizi, yapay sinir ağı ve bulanık yapay sinir ağı tekniği karşılaştırılmıştır.	Regresyon, YSA
Gültekin (2017)	Fiyat tahmini için yapay sinir ağı ve regresyon teknikleri karşılaştırılmıştır.	YSA
Akdağ (2015)	Enflasyon tahmini için box-jenkins ve yapay sinir ağı teknikleri karşılaştırılmıştır.	Box-jenkins
Doğan (2012)	Talep tahmini için yapay sinir ağı, arima ve anfis teknikleri karşılaştırılmıştır.	ARIMA
Tepehan (2011)	PISA başarı puanı tahmininde yapay sinir ağı ve lojistik regresyon teknikleri kullanılmıştır.	YSA
Bozdağ (2011)	Havayolu yolcu tahmini için box-jenkins ve yapay sinir ağı teknikleri karşılaştırılmıştır.	YSA
Muzır (2011)	Kredi risk analizi için ekonometrik modeller, yapay sinir ağı ve mars modellerini karşılaştırmıştır.	YSA

Gerçekleştirilen literatür taraması sonucunda; tahminleme işlemi için yapay sinir ağı ve klasik istatistik teknikler karşılaştırıldığında genellikle yapay sinir ağı tekniğinin daha başarılı sonuçlar verdiği görülmüştür.

3.9. R Programlama Dili

R programlama dili 1970'ler sonrasında geliştirilmiş olan S programlama dilinin ileri versiyonu olan ücretsiz ve açık kaynak koldu bir programlama dilidir. R dili çoğunlukla istatistiksel analiz ve veri madenciliği uygulamaları için tercih edilmektedir. Ross Ihaka ve Robert Gentleman'ın 1991 yılında geliştirdikleri programlama dili ilk olarak 1993 yılında genel kullanıma sunulmuş, 1995 yılında ise açık kaynak kodlu lisansını edinmiştir. 2000 yılına gelindiğinde ise v.1.0.0. numaralı sürümü piyasaya sürülerek oldukça geniş bir kullanıcı potansiyeline sunulmuştur. R programı açık kaynak kodlu ve lisans bedeli talep etmemesinin yanında oldukça esnek bir programdır ve çok çeşitli alanlarda kullanılmaktadır. Bu yönüyle, farklı sektörlerde binlerce yazılımcının kullanabildiği ve sürekli geliştirilen bir programlama dili olmuştur. Kütüphanesinde biyolojiden fiziğe, finanstan makine öğrenmesine kadar pek çok alanda paketler bulunduran yazılım teknik açıdan

oldukça zengin bir analiz ortamı sunmaktadır. Programın sağladığı diğer bir önemli katkı ise multi disipliner etkisi ile oluşturduğu etkileşim sayesinde, yöntemlerinin pek çok disiplinde kullanılabiliyor olmasıdır. Örneğin uydu görüntüleme için geliştirilen paketler aynı zamanda iktisadi gelişmişlik veya ülke ekonomik gelişimlerini incelemek için kullanılabilmektedir (Şirin, 2018: 3).

R programlama dili farklı hedeflere yönelik oldukça fazla uygulamayı da içermektedir. İstatistik, meta analiz, veri madenciliği, makine öğrenmesi gibi uygulamaları ve bu amaca yönelik kullanılan SPSS, CMA, SAS, WEKA, MATLAB gibi farklı yazılımları da barındırmaktadır. Büyük veri yönetimi süreçlerinde kullanılabilen R programlama dili; üniversite, finans kurumları, fabrikalar, yardım kurumları ve hastaneler gibi pek çok alanda sıklıkla tercih edilmektedir. R programlama dilinin diğer istatistik paket programlarına göre avantajları (Eser, Aksu ve Güzeller, 2019: 2);

- Kaynak kodu herkesin geliştirmesi ve kullanımına açık ve ücretsizdir,
- Birden fazla amaç için çözümler üretebilmektedir,
- İşletim sistemi ayrımı bulunmamaktadır,
- Geliştirici topluluğunun dinamik bir yapıda olması nedeniyle farklı platformlarda yaşanan sorunları hızla çözebilmektedir,
- Hazır kod bloklarının kullanımına imkân tanımaktadır,
- Hem profesyonel yazılımcılar hem de amatörlerin sistem içerisinde uzman istatistikçi ve yazılımcılardan destek alabileceği platformlara sahiptir,
- Hem geliştirilen kod hem de çıktı tek bir dökümanda yer almaktadır,
- Çok büyük miktardaki veriyle çalışabildiği için araştırmacıların hızla sonuca ulaşmasına imkân sunmaktadır,
- Muadil yazılımlara göre miktar ve kalite açısından daha fazla öğrenme kaynağı bulunmaktadır,
- İleri düzeyde hesaplama için C, C++ ve Fortran gibi yazılımlarla birlikte çalışabilmektedir,
- Oldukça gelişmiş ve ayrıntılı grafikler oluşturabilmektedir,
- Farklı tipteki veri dosyalarını okuyabilmektedir,

- Hem veri işleme ve veri madenciliği alanlarda pek çok yöntemi hem de meta analiz ve sosyal ağ analizleri gibi konularda çalışabilmektedir.

Son yıllarda oldukça popüler olan R programlama dili veri biliminin ve büyük veri işlemenin önemiyle paralel olarak ilerlemektedir. Uzun yıllardır gelişmekte olan istatistik, lineer matematik, yöneylem araştırması, yapay zekâ ve makine öğrenmesi gibi veri biliminin temelini oluşturan tekniklere de katkı sunan R programlama dili; bu araçların tüm özelliklerini kullanıcıya neredeyse tek bir arayüz ile sunabilmektedir (Eser, Aksu ve Güzeller, 2019: 2). Bu çalışma kapsamında geliştirilen algoritmaların R kodları için bkz. Ek 1.

DÖRDÜNCÜ BÖLÜM

R PROGRAMLAMA DİLİYLE TAHMİN PERFORMANSI

KARŞILAŞTIRMASI

Tahmin konsepti, birtakım hipotezler altında bir değişkenin gelecekte alabileceği değerlerin daha önceden ve yaklaşık biçimde hesaplanması olarak tanımlanmaktadır. Doğruluk derecesi yüksek tahminler, geleceğe yönelik stratejik karar alma aşamasında da başarıyı berebarinde getirmektedir. Tahmin işlemini gerçekleştirmeye yönelik model geliştirme bazı zorluklara da neden olmaktadır. Hem nicel hem de nitel tahmin tekniklerinin kaynağını, hedef değişkene ait gözlem değerleri oluşturmaktadır. Geçmiş ve şimdiki dönemin gözlenen değerleri kullanılarak gelecek değerler belirli kurallara uyularak tahminlenmektedir (Ataseven, 2013; 101).

Günümüzde teknolojinin hızla gelişmesi beraberinde ekonomi ve finans alanında kullanılan geleneksel istatistiksel tekniklerinde değişmesini sağlamıştır. Teknoloji; kurumsallık, karlılık ve büyüme için oldukça önemli bir anahtar görevini görmektedir. Aynı zamanda ulusal ekonomilerin refahı ve uluslararası rekabet gücü açısından da oldukça büyük önem arz etmektedir. Teknolojinin etkin yönetimi; bir organizasyondaki stratejik ve operasyonel hedeflerin geliştirilmesi için gerekli olan yeteneklerin planlanması ve uygulanması adımlarında gereken mühendislik, bilim ve yönetim disiplinlerini de birbirine bağlamaktadır. Teknoloji yönetimi temel araştırmalar da dâhil olmak üzere; uygulamalı araştırma, ar-ge, tasarım, inşaat, imalat, kalite kontrol ve teknoloji transferi gibi pek çok farklı alanda faaliyetler

içermektedir. Bu bakımdan teknoloji yönetimi sadece ar-ge değil aynı zamanda süreç yönetimini de kapsadığı için oldukça geniştir. Bu açıdan teknoloji yönetimi aslında firmaların teknoloji stratejilerini iş stratejisiyle bütünleştirme çabasıdır. Bu entegrasyon; araştırma, üretim ve hizmet fonksiyonları firmanın pazarlama, finans ve insan kaynakları fonksiyonları ile bilinçli bir şekilde koordine edilmesini gerektirmektedir. Bütün bu görevler yeni yönetsel beceriler, teknikler ve düşünme biçimleri gerektirmektedir (Martino, 1993). Yönetici ve teknik profesyonellere teknolojiyi kullanarak yeni bilgiler sunmak tahmin yöntemlerinin de kullanılmasını gerektirmektedir.

Bu çalışmada Türkiye’de ihracat endeksi verisinin tahmin edilmesi için Türkiye İstatistik Kurumu ve Merkez Bankası web sitelerinde yayınlanan istatistik verileri incelenerek bir veri ambarı oluşturulmuştur. Çalışma kapsamında oluşturulan veri ambarında Türkiye ihracat verisi üzerinde etkisi olduğu düşünülen değişkenler ve ihracat endeksi verisi kullanılmıştır. İhracat tutarı üzerinde etkisi olduğu düşünülen değişkenlere yapılan literatür taraması sonucunda karar verilmiştir. Gerçekleştirilen literatür taramasında ihracatı etkileyen faktörlerin iç ve dış faktörler olarak ikiye ayrıldığı, böylece ülkelerin iç ekonomisinin ve ülke dışı ekonomik gelişmelerin ihracata etkileri olduğu görülmüştür. Aaby ve Slater tarafından 1989 yılında gerçekleştirilen çalışmada ihracatı etkileyen faktörler; firmanın teknoloji kullanımını, kalite politikaları, pazar potansiyeli, devlet destekleri olarak belirlenmiştir. Zou ve Stan tarafından 1998 yılında gerçekleştirilen çalışmada ihracatı etkileyen faktörler; ihraç edilecek ürünle ilgili üretim yeterlilikleri, firmanın uluslararası yeterlilikleri, firmanın teknoloji kullanımı, yerel piyasa dinamikleri olarak belirlemişlerdir. Yücel tarafından 2006 yılında gerçekleştirilen çalışmada; endüstrilerdeki teknolojik gelişmeler ve dış pazar koşullarının ihracat performansını etkilediği sonucuna ulaşılmıştır. Sousa, Martinez ve Coelho tarafından 2008 yılında gerçekleştirilen çalışmada; pazarlama faaliyetleri, firmanın ürünle ilgili yeterlilikleri, yurt dışı piyasalarındaki hareketlilikler, ülke içerisindeki ihracat faaliyetlerinin ihracat performansına etkisi olduğu sonucuna ulaşılmıştır. Hultman, Robson ve Katsikeas tarafından 2009 yılında gerçekleştirilen çalışmada ihracat performansını etkileyen faktörlerin; ürünün piyasa koşullarına olan uyumu, teknolojik yeterlilik ve ihracata yönelik tüm konuların istatistiksel olarak anlamlı bir etkisi olduğu sonucuna ulaşılmıştır. Düzgün ve Taşcı tarafından 2014 yılında gerçekleştirilen çalışmada

ihracatı etkileyen faktörlerin; kur, ihracat endeksi, yurtiçi makro-ekonomik değişkenler (GSYİH, enflasyon) olduğu sonucuna ulaşılmıştır.

İhracat tutarına etkisi olan faktörler bağımsız değişkenler bazında da ayrıca literatür taraması yapılarak incelenmiştir. Saygılıoğlu Erdoğan tarafından 2016 yılında gerçekleştirilen çalışmada ihracatı etkileyen faktörlerin; ihracat endeksi, tüketim malları ithalatı ve döviz kuru olduğu sonucuna ulaşılmıştır. Dinçer tarafından 2021 yılında imalat sanayii özelinde gerçekleştirilen çalışmada ihracata etkisi olan faktörler; ihracat hacmi, teknoloji yatırımları, döviz kuru ve ortaklıklar olarak belirlenmiştir. Durgun ve Çapık tarafından 2018 yılında gerçekleştirilen çalışmada ise yine arge ve teknolojik ürünlerin ihracata olumlu etkisi olduğu görülmüştür. Tipi tarafından 2019 yılında gerçekleştirilen bir araştırmada ise yurtiçi üretim maliyetleri, teknoloji açısından yenilikçi ürünlerin ihracat performansına etkisi olduğu görülmüştür. Bayır tarafından 2006 yılında gerçekleştirilen bir çalışmada ise ihracat değerine etkisi olduğu düşünülen bağımsız değişkenler döviz alış kuru, üretim endeksi, sınai kapanış fiyatları ve verimlilik endeksi verileri kullanılarak kurulan regresyon modeli anlamlı bulunmuştur.

Gerçekleştirilen literatür taraması sonucu ihracata etkisi olduğu düşünülen makro ve mikro bağımsız değişkenler incelenmiştir. Bu değişkenler içerisinde ihracat tutarına en çok etkisi olduğu düşünülen ve literatürde sıklıkla kullanıldığı görülen; üretim endeksi, sınai kapanış değeri, dolar alış değeri, teknoloji endeksi ve ihracat endeksi verileri kurulacak olan modeller için bağımsız değişkenler olarak belirlenmiştir. Belirlenen bağımsız değişkenlerden üretim endeksi; yıllar içerisinde üretim faaliyetlerinde görülen değişimin karşılaştırmalı olarak izlenebildiği değerdir (Cesur ve Kozhan, 2022: 170 ve Koç, Şenel ve Kaya, 2017: 2). Sınai kapanış değeri ise sanayi üretim değerinin kapanış seansı fiyatı hesaplanarak tek bir fiyat üzerinden işlem yapıldığı değerdir. Teknoloji endeksi değeri ise; teknoloji fiyat ve getiri kapanış değerleri kullanılarak hesaplanmaktadır (Borsa İstanbul, 2022). İhracat endeksi değeri ise; ihracat birim değerinde meydana gelen değişimi gösterir ve Türkiye İstatistik Kurumu tarafından ihracatı yapılan tüm ürünler üzerinden gerekli hesaplama yapıp birim değerler birleştirilerek endeks verisi elde edilmektedir (Öztemiz, 2021: 51).

Belirlenen değişkenler Türkiye İstatistik Kurumu ve Merkez Bankası web sayfalarından alınarak veri ambarı oluşturulmuştur. Oluşturulan veri ambarı kullanılarak R programlama dilinde yapay sinir ağı algoritması geliştirilerek ihracat

değeri tahmini yapılmıştır. Ayrıca yapay sinir ağı yönteminin klasik istatistik tahmin teknikleri olan zaman serisi ve regresyon teknikleriyle karşılaştırması da yapılmıştır. Yine R programlama dilinde zaman serisi ve regresyon analizi algoritmaları geliştirilmiş ve ihracat değeri tahmin edilmiştir. Geliştirilen her üç modelde tahmin sonuçları incelenerek hangi teknikle daha başarılı tahmin sonuçları elde edildiği incelenmiştir.

4.1. Veri Setinin Oluşturulması

Bu çalışmada kullanılacak olan veri ambarı Türkiye İstatistik Kurumu ve Merkez Bankası verilerinden derlenmiştir. Veri ambarı içerisinde yer alan ve İhracat tutarı üzerinde etkisi olduğu düşünülen bağımsız değişkenler; üretim endeksi (uret_endeks), sınai kapanış değeri(sınai_kap), dolar alış değeri(usd_al), teknoloji endeksi(tekn_endeks), ihracat endeksi(ihr_endeks) aylık değerleri olarak belirlenmiştir. İhracat tutarı verisi ise hedef değişken olarak belirlenmiştir.

Şekil 15: Tahmin İçin Kullanılacak Veri Ambarı

yil	ay	uret_endeks	sınai_kap	usd_al	tekn_endeks	ihr_endeks	ihr_tutari
2005	Ocak	55,6	216,4	1,35	79,17	62,9	5515454,0
2005	Şubat	50,1	228,5	1,31	86,62	65,0	5621469,0
2005	Mart	56,3	220,8	1,30	100,94	74,5	6413610,1
2005	Nisan	55,0	202,4	1,35	90,82	74,7	5999138,9
2005	Mayıs	58,5	197,02	1,37	86,08	75,3	6018789,1
2005	Haziran	59,1	211,8	1,35	90,40	72,1	5901948,3
2005	Temmuz	59,7	226,8	1,33	100,64	71,7	5776712,6
2005	Ağustos	58,4	234,8	1,34	101,73	71,2	5370118,3
2005	Eylül	63,4	262,2	1,33	99,57	73,9	6603295,3
2005	Ekim	66,7	257,8	1,35	95,85	77,4	6746739,8
2005	Kasım	66,1	271,4	1,35	103,81	74,2	6344016,3
2005	Aralık	66,4	301,2	1,35	121,54	78,9	7028780,6
2006	Ocak	57,1	320,14	1,33	143,17	67,5	5832621,7
2006	Şubat	54,6	338,43	1,32	158,94	70,5	6025779,7
2006	Mart	63,6	331,8	1,33	153,92	85,0	7213485,3
2006	Nisan	61,1	337,78	1,33	153,67	80,4	6524032,2
2006	Mayıs	64,6	322,08	1,41	137,84	81,5	6869175,1
2006	Haziran	65,5	279,23	1,59	104,81	88,9	7647391,6
2006	Temmuz	65,0	279,70	1,55	102,72	82,7	7082932,8
2006	Ağustos	62,4	290,68	1,46	106,97	82,0	6589759,5


Şekil 15’de Türkiye İstatistik Kurumu ve Merkez Bankası verileri ile oluşturulan veri ambarı içerisinde yer alan orijinal veriler görülmektedir. Veri ambarı içerisinde yer alan veriler; yapay sinir ağı, zaman serisi ve regresyon analizi teknikleriyle analiz yapılabilecek şekilde aylık olarak düzenlenmiştir. Şekil 15’de görülen veri ambarı içerisindeki; uret_endeks, sınai_kap, usd_al, tekn_endeks, ihr_endeks verileri bağımsız değişkenler ihr_tutari ise bağımlı değişken olarak belirlenmiştir. Çalışma kapsamında 2005:01 ile 2019:12 dönemleri arasındaki verilerin analizi gerçekleştirilmiştir. İlgili döneme ait veri ambarı içerisinde yer alan bağımsız değişkenler grafiksel olarak incelenerek yorumlanmıştır.

Şekil 16: 2005-2019 Arası Üretim Endeksi (Aylık)




Şekil 16 ile veri ambarı içerisinde yer alan üretim endeksi (uret_endeks) değerinin 2005-2019 yılları arasındaki hareketleri incelenmiştir. Üretim endeksi verisinde artan trend görülmektedir.

Şekil 17: 2005-2019 Arası Sınai Kapanış Değerleri




Şekil 17 ile sınai kapanış değerleri görülmektedir. Sınai kapanış değerlerinde değerinde yıllar bazında artan bir trend görülmektedir. Ayrıca sınai kapanış verilerinde 2016 yılından sonra yığılım olduğu da grafikten anlaşılmaktadır.

Şekil 18: 2005-2019 Arası Döviz Alış Değerleri




Şekil 18 ile döviz alış (ABD Doları) aylık ortalama TL değeri olarak görülmektedir. Döviz alış değerinde yıllar bazında artan bir trend görülmektedir. Ayrıca döviz alış verilerinde 2018 yılından sonra yığılma olduğu da grafikten anlaşılmaktadır.

Şekil 19: 2005-2019 Arası Teknoloji Endeksi Değerleri



Şekil 19 ile 2005 yılı Ocak ayı ve 2019 Yılı Aralık ayı tarihleri arasındaki teknoloji endeksi değeri görülmektedir. Grafikte 2005-2010 yılları arasında yığılma, 2011-2019 yılları arasında ise artan trend görülmektedir. Ayrıca yine 2017-2019 yılları arasında ülkemizde teknoloji endeks değerlerinde bir yığılma gözlemlenmektedir.

Şekil 20: 2005-2019 Arası İhracat Endeksi Değerleri



Şekil 20 ile numaralı grafikte 2005 yılı Ocak ayı ve 2019 Yılı Aralık ayı tarihleri arasındaki ihracat endeksi değeri görülmektedir. İhracat endeks verisi incelendiğinde artan trend görülmektedir.

Veri seti uygulamanın ilk tekniği olan yapay sinir ağına sunulmadan önce normalize edilmelidir (Bayır, 2006: 100). Bu nedenle yapay sinir ağı modeli kurulmadan önce veriler $[-1, 1]$ aralığına indirgenmiş ve normalizasyon yapılmıştır. Şekil 21’de normalizasyon yapılmış veri setinin bir kısmı görülmektedir.


Şekil 21: Normalize Edilmiş Veri Setinin Görünümü

uret_endeks	s.nai_kap	usd_al	tekn_endeks	ihr_endeks	ihr_tutari
0.068322981	0.023667722	0.034615385	0.027173873	0.000000000	0.01429152
0.000000000	0.034210865	0.026923077	0.032666151	0.01838879	0.02471646
0.077018634	0.027501592	0.025000000	0.043223119	0.10157618	0.10261131
0.060869565	0.011469045	0.034615385	0.035762468	0.10332750	0.06185446
0.104347826	0.006781268	0.038461538	0.032268053	0.10858144	0.06378676
0.111801242	0.019659585	0.034615385	0.035452836	0.08056042	0.05229727
0.119254658	0.032729597	0.030769231	0.043001954	0.07705779	0.03998227
0.103105590	0.039700269	0.032692308	0.043805522	0.07267951	0.000000000
0.165217391	0.063574823	0.030769231	0.042213130	0.09632224	0.12126392
0.206211180	0.059740953	0.034615385	0.039470677	0.12697023	0.13536947
0.198757764	0.071591097	0.034615385	0.045338936	0.09894921	0.09576783
0.202484472	0.097556853	0.034615385	0.058409820	0.14010508	0.16310383
0.086956522	0.114059921	0.030769231	0.074355855	0.04028021	0.04548007
0.055900621	0.129996621	0.028846154	0.085981791	0.06654991	0.06447417


4.2. R Yazılımında Yapay Sinir Ağı Geliştirilerek Optimal Modelin Belirlenmesi

Normalizasyon sonrasında veri seti yapay sinir ağı eğitimine uygun biçimde rastgele olarak eğitim ve test olarak ayrılmıştır. Eğitim ve test veri kümesi literatürde sıklıkla geçtiği biçimde %80 eğitim %20 test olarak biçimde ayrılmıştır. Yapay sinir ağı modelinde bağımlı değişken; ihr_tutari bağımsız değişkenler ise; uret_endeks, sinai_kap, usd_al, tekn_endeks ve ihr_endeks olarak belirlenmiştir. Veri seti içerisinde eksik veri ve uç değerler olup olmadığı kontrol edilmiştir. Bu aşamadan sonra yapay sinir ağının katman sayısının belirlenmesinde farklı katman sayısına sahip modeller R programında oluşturulup görselleştirilmiştir.


Şekil 22: İki Gizli Katmanlı (4,2) Yapay Sinir Ağı




Şekil 23: İki Gizli Katmanlı (5,3) Yapay Sinir Ağı




Şekil 24: İki Gizli Katmanlı (6,4) Yapay Sinir Ağı




Şekil 25: İki Gizli Katmanlı (6,5) Yapay Sinir Ağı




Şekil 26: İki Gizli Katmanlı (8,3) Yapay Sinir Ağı




Şekil 27: İki Gizli Katmanlı(8,5) Yapay Sinir Ağı




Şekil 28: Üç Gizli Katmanlı (5,4,3) Yapay Sinir Ağı



Şekil 29: Üç Gizli Katmanlı (3,6,7) Yapay Sinir Ağı



Şekil 30: Üç Gizli Katmanlı (4,5,8) Yapay Sinir Ağı



Eğitim verisi üzerinde çalışarak en başarılı sonucu elde edecek yapay sinir ağının belirlenmesi için birden fazla yapay sinir ağı oluşturulmuştur. Oluşturulan yapay sinir ağları içerisinde en yüksek performansa sahip ağın belirlenmesi için Bayır (2006), Karahan (2011), Calp (2019) ve Çınar (2018) çalışmalarında gerçekleştirildiği gibi birden fazla yapay sinir ağı denemesi yapılarak sonuçları karşılaştırılmıştır. Oluşturulan yapay sinir ağları içerisinde katman sayıları (4-2), (5-3), (6-4), (6-5), (8-3), (8-5), (5-4-3), (3-6-7), (4-5-8) olan farklı modeller bulunmaktadır. Tüm modeller R programlama dilinde “neuralnet” fonksiyonu ile tanımlanmıştır. Yapısal olarak bu fonksiyon her iterasyonda ağırlıkları değiştirmekte ve hata oranını düşürüp her adımda yeni ağırlık katsayısı belirlemektedir. Ağırlık katsayıları optimum seviyeye ulaştığında ise iterasyonu durdurmaktadır (Çınar, 2018). Uygulama aşamasında denemesi yapılan tüm yapay sinir ağı modellerinde girdi ve çıktı değişkenleri sabit tutulmuş yalnızca ara katman sayıları ve nöron sayıları değiştirilerek farklı yapay sinir ağı modelleri denenmiştir.


Yapay sinir ağının eğitilmesi; kullanılan veri seti için minimum MSE değerinin elde edilmesidir. Yapay sinir ağında tahmin başarısının ölçülmesi için literatürde sıklıkla MSE ve RMSE değeri kontrol edilerek en düşük değer başarılı kabul edilmektedir (Calp, 2017: 82; Bayır, 2006: 102; Karahan, 2011: 113; Gandomi ve Roke; 2015: 66). Bu nedenle eğitim ve test veri seti oluşturulan modellere ayrı ayrı sunularak minimum hata düzeyine ulaşılması hedeflenmiştir. Eğitim ve test veri setleri için yukarıda denemesi yapılan tüm yapay sinir ağı modellerinde MSE ve RMSE hata değerleri kontrol edilmiştir. Tablo 8’de deneme yapılan farklı yapay sinir ağı modellerinin eğitim ve test verilerinde elde edilen MSE ve RMSE hata katsayıları görülmektedir.

Tablo 8: Yapay Sinir Ağı Modellerinin Hata Oranları


Ağ Topolojisi	MSE(Eğitim)	RMSE(Eğitim)	MSE(Test)	RMSE(Test)	İTERASYON
YSA (4,2)	0.002419855	0,048989	0.001526044	0,038729	687
YSA (5,3)	0.002237186	0,046904	0.0009450562	0.03	1391
YSA (6,4)	0.002517687	0.05	0.001318967	0,036055	355
YSA (6,5)	0.003696617	0.06	0.001608304	0.04	269
YSA (8,3)	0.003570218	0,05916	0.003250909	0,056568	499
YSA (8,5)	0.002492705	0,048989	0.001616792	0.04	579
YSA (5,4,3)	0.003371487	0,057445	0.003153103	0,055677	445
YSA (3,6,7)	0.003570474	0,05916	0.00296052	0,053851	301
YSA (4,5,8)	0.003488503	0,058309	0.00335205	0,057445	223

R yazılımında geliştirilen yapay sinir ağı modelinde yapılan her iterasyon sonrasında ağırlığı değiştirmektedir. Hata oranı düşürülerek her seferinde farklı ağırlıklar belirlenmekte ve belirlenen ağırlıklar en optimal düzeye geldiğinde işlem sonlandırılmaktadır (Çınar, 2018). Tablo 8’de görüldüğü gibi en düşük hata oranına sahip yapay sinir ağı iki gizli katmandan oluşan birinci katmanında 5 ikinci katmanında ise 3 eleman içeren yapay sinir ağı olarak belirlenmiştir. Tahmin verisi için kullanılacak yapay sinir ağı YSA(5,3) olarak belirlenmiştir. Aşağıda YSA(5,3) yapay sinir ağı ve diğer deneme yapay sinir ağlarının grafiksel olarak gösterimleri bulunmaktadır.


Şekil 31: YSA(5,3) ile YSA(4,2) Ağlarının R Programında Grafiksel Olarak Karşılaştırılması




Şekil 32: YSA(5,3) ile YSA(6,4) Ağlarının R Programında Grafiksel Olarak Karşılaştırılması




Şekil 33: YSA(5,3) ile YSA(6,5) Ağlarının R Programında Grafiksel Olarak Karşılaştırılması




Şekil 34: YSA(5,3) ile YSA(8,3) Ağlarının R Programında Grafiksel Olarak Karşılaştırılması




Şekil 35: YSA(5,3) ile YSA(8,5) Ağlarının R Programında Grafiksel Olarak Karşılaştırılması




Şekil 36: YSA(5,3) ile YSA(5,4,3) Ağlarının R Programında Grafikselleştirilmesi



Şekil 37: YSA(5,3) ile YSA(3,6,7) Ağlarının R Programında Grafikselleştirilmesi




Şekil 38: YSA(5,3) ile YSA(4,5,8) Ağlarının R Programında Grafikselleştirilmesi



31 ve 38 numaralı karşılaştırmalı grafiklerde test verisi üzerinde çalıştırılan modellerin görsel karşılaştırmaları da yer almaktadır. En küçük hata oranlarına sahip ve tahmin için kullanılan (5,3) topolojisine sahip yapay sinir ağının, diğer ağ topolojilerine göre grafik üzerinde yer alan eğriye daha yakın sonuçlar verdiği görülmektedir.

Şekil 39: Yapay Sinir Ağında Yer Alan Bağımsız Parametrelerin Önem Düzeyi



Yapay sinir ağında yer alan parametrelerin sahip olduğu ağırlıklar klasik bir regresyon modelinin içerdiği parametrelerin katsayılarına kısmen benzerlik göstermektedir ve bağımsız değişkenler arasında bulunan ilişkileri tanımlama amaçlı kullanılabilir. R programlama dili içerisinde yer alan ve bir bağımlı değişken için bağımsız parametrelerin önem düzeyini belirleyen “garson” algoritması kullanılarak yapay sinir ağındaki değişkenlerin önemi belirlenmiştir. Bu algoritma parametre önem düzeyini; spesifik bir bağımsız değişkene ait ilgili düğümler içerisindeki tüm bağlantıları keşfederek belirlemektedir. Her bir giriş düğümünde bağlantılar bulunarak diğer tüm girişlere göre ölçeklenmektedir (Çınar, 2018). Şekil 39’da yapay sinir ağı parametrelerinin önem düzeyleri gösterilmektedir. Buna göre ihracat tutarı bağımlı değişkeninin tahmininde en önemli bağımsız değişkenin ihracat endeksi olduğu görülmektedir. İkinci seviyede öneme sahip değişkenlerin ise dolar alış, teknoloji endeksi ve üretim endeksi olduğu görülmektedir. İhracat endeksi tahmini için önem seviyesi en düşük değişken ise sınai kapanış değeri olarak belirlenmiştir.

4.3. R Programında Regresyon Modeli Geliştirilmesi

Regresyon modelleri ile farklı değişkenler arasındaki ilişki modellenmektedir. Regresyon analizinde bir bağımlı değişken bir ya da daha fazla bağımsız değişken ile şekillenebilmektedir (Arslan, 2017: 339). R programlama dilinde regresyon algoritması geliştirilerek eğitim veri seti üzerinde öğrenme işlemi gerçekleştirilmiştir. Diğer tahmin tekniklerinde olduğu gibi regresyon modeli için de veri seti %80 eğitim ve %20 test olarak ayrılmıştır. En iyi modeli belirlemeye yönelik denemeler öncesinde regresyon yönteminin kullanılabilmesi için gereken normallik, varyans homojenliği ve çoklu doğrusallık varsayımlarının sağlandığı kontrol edilerek model denemelerine geçilmiştir.

Nihai model belirlenmeden önce yapılan denemelerde, sınai kapanış bağımsız değişkeni yapay sinir ağı modelinde olduğu gibi regresyon modeli için de anlamsız bulunduğundan modelden çıkarılmıştır. Şekil 40’da geliştirilen regresyon algoritmasının sonuçlarını içeren ekran görüntüsü bulunmaktadır. “Coefficients” başlığı altında hesaplanan katsayıların model için anlamlı olup olmadığı görülmektedir. “Coefficients” bölümünün altında yer alan “Signif. codes” bölümünde * işareti ile belirtilen anlamlılık seviyelerine göre parametrelerin model için anlamlılığı değerlendirilmektedir (Arslan, 2017: 350). Buna göre oluşturulan regresyon modelinde ihracat endeksi (ihr_endeks), üretim endeksi (uret_endeks), dolar alış (usd_al) ve teknoloji endeksi (tekn_endeks) bağımsız değişkenleri model için anlamlı bulunmuş ve nihai regresyon modeli belirlenmiştir. Regresyon algoritmasıyla elde edilen bağımsız değişkenlerin önem seviyeleri Şekil 31 ile verilen değişken önem seviyeleriyle benzer çıkmıştır.

Şekil 40: İhracat Tutarı Regresyon Modeli


```
Call:
lm(formula = ihr_tutar ~ uret_endeks + usd_al + tekn_endeks +
    ihr_endeks, data = veri_egitim)

Deviance Residuals:
    Min       1Q   Median       3Q      Max
-0.287508  0.130813  0.284073 -0.076288  0.623917


Coefficients:
            Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.13011    0.01407   2.698 0.030830 *
uret_endeks  0.62805    0.07924   2.394 0.039121 *
usd_al       0.91095    0.06930   1.744 4.89e-15 ***
tekn_endeks  0.87045    0.05306   3.077 0.002884 **
ihr_endeks   1.23954    0.08233   6.076 < 2e-16 ***
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

Eğitim veri seti üzerinde öğrenmesini tamamlayarak test verisi üzerinde denemesi gerçekleştirilen regresyon modeline ait R kare değeri: 0.871 ve MSE: 0.005989876 hesaplanmıştır.

Şekil 41: Regresyon ve YSA Modellerinin Test Verisi Deneme Grafikleri



Şekil 42: Regresyon ve YSA Modellerinin Test Veri Üzerinde Birlikte Gösterimi




Regresyon ve yapay sinir ağı tekniklerinin performansı hem grafiklerden hem de hata oranlarından incelendiğinde; yapay sinir ağı tekniğinin regresyon analizine göre daha başarılı sonuçlar verdiği görülmektedir. Tahmin için kullanılacak olan yapay sinir ağı modeli şekil 41 ve şekil 42’de görüldüğü gibi gerçek değere daha yakın tahminler gerçekleştirmiştir.

4.4. R Programında Zaman Serisi Modelinin Geliştirilmesi


Zaman serisi analizi yapılabilmesi için otokorelasyon, trend gibi varsayımların sağlanması gerekmektedir. Bu nedenle zaman serisi analizi yapacağımız veri seti üzerinde analiz işlemi yapılmadan önce bazı kontroller gerçekleştirilmiştir. Veri seti üzerinde ilk inceleme otokorelasyon olup olmadığına bakılması olmuştur. Şekil 43 ile gösterilen otokorelasyon grafiğinde veri setinde otokorelasyon olduğu görülmektedir.

Şekil 43: Otokorelasyon Grafiği



Daha sonra veri setinde trend olup olmadığı incelenmiştir.

Şekil 44: Veri Setine Ait Trend İnceleme Grafiği




Şekil 44 incelendiğinde veride trend olduğu görülmektedir. Zaman serisi analizi yapılabilmesi veri setini trend etkisinden arındırmak gerekmektedir. Bu nedenle zaman serisi analizi yapılacak veri seti için fark alınması gerekmektedir. Zaman serisi verisi için R programında geliştirilen algortima ile farkı alınarak veri seti tekrar incelenmiştir. Şekil 45 ve 46’da ADF (Augmented Dickey-Fuller Test) test sonuçlarından varsayımların sağlandığı ve veri setinin durağan hale geldiği görülmektedir.

Şekil 45: ADF Testi Sonuçları

```
Augmented Dickey-Fuller Test
data: detrend
Dickey-Fuller = -5.8465, Lag order = 5, p-value = 0.01
alternative hypothesis: stationary
```

Şekil 46: Veri Setinin Farkı Alındıktan Sonra Durağanlık Kontrolü Grafikleri



Zaman serisi analizi gerçekleştirirken otokorelasyon olup olmadığının testi pek çok farklı teknikle gerçekleştirilebilmektedir. Ancak literatürde yaygın olarak kullanılan yöntem Durbin-Watson (DW) testidir. Durbin-Watson katsayısı $0 \leq DW \leq 4$ aralığında bir değere sahip olabilmektedir. Durbin-Watson katsayısı 2’ye yakın bir değere sahipse modelde otokorelasyon bulunmadığı söylenebilmektedir (https://cdn-acikogretim.istanbul.edu.tr/auzefcontent/20_21_Guz/ekonometri/14/index.html Erişim Tarihi: 15.01.2022). Şekil 47’de görüldüğü gibi Durbin-Watson test sonuçlarında test katsayısının 1.8601 olduğu ve 2’ye yakın bir


değere sahip olduğu görülmektedir. Bu bilgiden hareketle serinin otokorelasyona sahip olmadığı söylenebilmektedir.

Şekil 47: Durbin-Watson Test Sonuçları

```
Durbin-watson test
data: detrend_lineer_model
DW = 1.8601, p-value = 0.1795
alternative hypothesis: true autocorrelation is greater than 0
```

Bu işlemler sonrasında veri seti analiz yapılabilir duruma getirilmiştir. Yapay sinir ağı ve regresyon uygulamalarında olduğu ver seti zaman serisi analizi için %80 ve %20 oranında eğitim ve test verisi olarak ayrılmıştır. Bu aşamada yine en iyi sonuç veren modeli bulabilmek için deneme yanılma yoluyla birkaç farklı model denemesi gerçekleştirilecektir. İlk deneme yapılan model Şekil 48 ile görülen mevsimsel naive model eğitim verisi üzerindeki başarısı görülmektedir.

Şekil 48: Mevsimsel Naive Model Eğitim Verisi Üzerindeki Başarısı



Mevsimsel naive modele ait hata değerleri ise Tablo 9 ile gösterilmektedir.

Tablo 9: Mevsimsel Naive Model Hata Değerleri

	MSE	RMSE
Eğitim Veri Seti	0.187	0.432434

Şekil 49’da veri seti üzerinde denenen ARIMA modelleri görülmektedir. Bu denemeler sonucunda eğitim veri seti üzerinde ARIMA modelleri içerisinde en uygun modelin ARIMA(1,0,0)(2,0,0) olduğu görülmektedir.

Şekil 49: Eğitim Verisi Üzerinde ARIMA Model Denemelerinin Sonuçları

```


ARIMA(2,0,2)(1,0,1)[12] with non-zero mean : Inf
ARIMA(0,0,0) with non-zero mean : 4280.419
ARIMA(1,0,0)(1,0,0)[12] with non-zero mean : 4256.981
ARIMA(0,0,1)(0,0,1)[12] with non-zero mean : 4262.542
ARIMA(0,0,0) with zero mean : 4278.376
ARIMA(1,0,0) with non-zero mean : 4279.816
ARIMA(1,0,0)(2,0,0)[12] with non-zero mean : 4255.202
ARIMA(1,0,0)(2,0,1)[12] with non-zero mean : Inf
ARIMA(1,0,0)(1,0,1)[12] with non-zero mean : Inf
ARIMA(0,0,0)(2,0,0)[12] with non-zero mean : 4258.006
ARIMA(2,0,0)(2,0,0)[12] with non-zero mean : 4257.299
ARIMA(1,0,1)(2,0,0)[12] with non-zero mean : 4257.342
ARIMA(0,0,1)(2,0,0)[12] with non-zero mean : 4255.306
ARIMA(2,0,1)(2,0,0)[12] with non-zero mean : 4258.324
ARIMA(1,0,0)(2,0,0)[12] with zero mean : 4253.074
ARIMA(1,0,0)(1,0,0)[12] with zero mean : 4254.88
ARIMA(1,0,0)(2,0,1)[12] with zero mean : Inf
ARIMA(1,0,0)(1,0,1)[12] with zero mean : Inf
ARIMA(0,0,0)(2,0,0)[12] with zero mean : 4255.918
ARIMA(2,0,0)(2,0,0)[12] with zero mean : 4255.141
ARIMA(1,0,1)(2,0,0)[12] with zero mean : 4255.183
ARIMA(0,0,1)(2,0,0)[12] with zero mean : 4253.179
ARIMA(2,0,1)(2,0,0)[12] with zero mean : 4256.133

Best model: ARIMA(1,0,0)(2,0,0)[12] with zero mean

```

ARIMA(1,0,0)(2,0,0) modeli ile gerçekleştirilen tahmin işleminin sonucu ise Şekil 50’de görülmektedir.

Şekil 50: ARIMA(1,0,0)(2,0,0) Modelinin Eğitim Verisi Üzerindeki Tahmin Başarısı



Tablo 10: ARIMA(1,0,0)(2,0,0) Modeli Hata Değerleri

	MSE	RMSE
Eğitim Veri Seti	0.104	0.322490

Test edilen zaman serisi modelleri içerisinde ARIMA(1,0,0)(2,0,0) modelinin daha iyi sonuçlar verdiği görülmektedir. İncelenen zaman serisi modellerine ait hata değerleri karşılaştırıldığında ARIMA modelinin daha başarılı sonuç verdiği tablo 11 ile görülmektedir.

Tablo 11: Zaman Serisi Modelleri Hata Değerleri Karşılaştırması

	MSE	RMSE
ARIMA	0.104	0.322490
Mevsimsel Naive	0.187	0.432434

4.5. Yapay Sinir Ağı, Regresyon ve Zaman Serisi Modellerinin Eğitim Verisi Üzerindeki Performanslarının Karşılaştırılması

Bu araştırma kapsamında literatürde uzun yıllardır kullanılan istatistiksel yöntemler olan regresyon analizi ve zaman serisi yöntemleri ile son dönemde sıklıkla tercih edilen bir teknik olan yapay sinir ağı teknikleri karşılaştırılmıştır.

Oluşturulan modellerin karşılaştırılması aşamasında tahmin değerlendirme için çeşitli analiz yöntemleri oluşturulmuştur. Belirlenen modeller kullanılarak gerçekleştirilen tahmin değerlerinin belirlenmesinde öncelikli olarak kayıp fonksiyonun belirlenmesi gerekmektedir. Kayıp fonksiyonu benzer biçimde en iyi doğruluk ölçütünün de belirlenmesi anlamına geldiğinden oldukça önemlidir. Tahmin değerlerinin doğruluğunu ölçmede kullanılabilecek pek çok kriter bulunmaktadır. Tahmin ve gerçek değer arasındaki sapma

$$e(t) = \chi(t) - f(t)$$

formülü ile ifade edilen en temel hata terimi kullanılarak hesaplanmaktadır. Bu doğruluk ölçütünün temelini sapma değerini ölçmek için kullanılan ortalama hata (Mean Error - ME) oluşturmaktadır. Ortalama hatanın temel alınarak oluşturulduğu diğer ölçütler Ortalama Hata Kareleri (Mean Squared Error - MSE), Ortalama Hata Kareleri Kökü (Root Mean Squared Error - RMSE) ve Ortalama Mutlak Hata (Mean Absolute Error – MAE) olarak bilinmektedir (Bayır, 2006: 107).

Ek olarak doğruluk ölçütlerindeki tahmin hatasına ait yüzde $p(t) = e(t) / \chi(t)$ oranı da benzer biçimde kullanılabilmektedir. Bu oran kullanıldığında ise kontrol edilen ölçütler; Ortalama Yüzde Hata (Mean Percent Error – MPE), Ortalama Yüzde Hata Kareleri (Mean Squared Percent Error – MSPE), Ortalama Yüzde Hata Kareleri Kökü (Root Mean Squared Percent Error – RMSPE) ve Ortalama Mutlak Yüzde Hata (Mean Absolute Percent Error, MAPE) olarak bilinmektedir (Bayır, 2006: 107).

Tablo 12: Tahmin Teknikleri Değerlendirme Ölçütleri

Tahmin Yöntemi	MSE(Test)	RMSE(Test)
Yapay Sinir Ağı (5,3)	0.0009450562	0.03
Regresyon	0.005989876	0.076811
ARIMA(1,0,0)(2,0,0)	0.104	0.322490


Bu çalışma kapsamında tahmin performansları değerlendirilecek olan yapay sinir ağı, regresyon ve zaman serisi tekniklerini değerlendirmek için Bayır (2006), Calp (2017), Karahan (2011), Yaman (2019) ve Turaç (2020) çalışmalarında kullanılan performans ölçütlerinden MSE ve RMSE ölçütleri kullanılmıştır. Tablo 12 ile görülen sonuçlardan tahmin teknikleri içerisinde en düşük hataya sahip modelin yapay sinir ağı (5,3) modeli olduğu görülmektedir. İhracat veri tahmini için yapay sinir ağı geleneksel istatistiksel tahmin yöntemleri olan regresyon analizi ve zaman serisi analiziyle karşılaştırıldığında daha başarılı tahmin sonuçları üretmiştir. Yapay sinir ağı (5,3) modeli ile tahmin işlemi gerçekleştirilmesine karar verilmiştir. Test verisi üzerinde gerçekleşen değerler ile her üç modele ait tahmin verileri Tablo 13 ile gösterilmiştir.

Tablo 13: Gerçekleşen ve Tahmin Edilen Değerler

Gerçek Değer	Regresyon(Tahmin)	YSA(Tahmin)	Zaman Serisi(Tahmin)
11.189.140,15	10.964.486,15	11.070.132,11	11.963.745
11.974.795,87	10.650.141,87	12.320.563,21	13.547.896
13.988.964,22	12.964.310,22	14.188.964,22	15.280.632
12.984.579,81	11.959.925,81	13.365.234,78	13.874.535
13.132.184,63	12.031.080,40	13.682.185,90	15.990.364
13.724.958,69	13.224.857,69	14.594.789,12	14.035.879
12.671.871,43	12.161.954,43	12.771.871,43	13.039.641
13.004.370,21	12.404.350,21	13.304.650,12	15.669.874
12.602.811,92	12.392.811,92	12.990.810,12	13.965.745
13.841.128,29	13.342.127,29	14.298.340,56	13.365.745
13.784.495,11	13.574.372,11	14.440.980,34	12.385.632
13.914.398,96	13.695.398,96	14.314.398,96	12.045.986
11.997.428,98	12.197.428,98	12.197.320,78	11.654.789
13.014.421,62	13.419.411,62	13.315.745,00	15.698.745
15.150.074,64	14.410.714,64	15.555.080,21	16.169.852
13.883.536,58	13.093.536,58	14.193.530,00	12.905.745
13.761.328,98	13.071.928,98	13.981.328,98	14.069.874
13.594.380,11	12.784.390,11	13.194.690,00	14.354.125
13.970.047,62	13.352.043,62	13.770.453,34	13.069.874
13.648.586,40	12.644.596,40	12.248.234,21	15.065.896

14.566.160,35	13.756.190,35	14.170.423,12	14.745.698
15.126.592,94	14.626.582,94	14.926.340,21	15.999.874
15.038.012,31	14.532.011,31	15.138.012,31	14.745.968
13.883.058,47	13.110.058,47	13.680.049,00	12.254.741
12.725.551,47	12.227.551,47	12.530.550,49	13.380.471
13.437.201,01	12.737.201,01	12.937.201,01	13.968.741
15.539.483,14	14.930.483,14	15.839.483,14	15.278.963
14.054.184,29	13.454.194,29	14.354.184,29	15.069.874
15.366.575,90	13.767.570,90	15.866.575,90	15.995.478
12.477.692,69	11.977.602,69	12.440.567,33	12.068.742
14.617.050,23	14.018.030,23	14.917.050,23	14.363.875
13.509.754,25	12.809.054,25	13.845.781,12	13.107.852
14.443.642,04	13.043.049,04	14.993.630,00	14.246.930
15.114.757,37	14.514.757,37	15.304.217,21	12.369.852
15.151.221,21	14.600.231,21	15.379.125,33	14.045.696
14.638.987,51	14.038.087,51	14.892.420,12	15.963.874

Şekil 51: Gerçek-Tahmin Değeri Karşılaştırmalı Grafiği



SONUÇ

Günümüz küresel ekonomileri oldukça dinamik bir yapıya sahiptir. Bu dinamik yapı gereği değişen bilgi teknolojileri artan veri ile çalışmayı zorunlu hale getirmektedir. Kullanılan verilerin çokluğu, büyük veri içerisindeki sarmal yapı ve veri ilişkilerindeki karmaşıklık geleneksel yöntemlerin yeterlilik kapasitesini düşürmektedir. Bu nedenle büyük miktarda ve karmaşık yapıdaki veri setiyle çalışabilecek yeni teknikler gerekmektedir.

Ham veriden bilgi çıkarımı geleneksel yöntemlerde çözümleme ve yorumlamadan ibarettir. Ancak artan veri miktarı eğitim, sağlık, ticaret, güvenlik gibi pek çok alanda veri işleme kaçınılmaz hale gelmiştir. Veri madenciliği teknikleri ile gizli kalmış veriden bilgi kazanımı oldukça yaygın biçimde kullanılmaktadır.

Tahmin gelecek gelecek öngörülerine dayanan ve kesinlik içermeyen bir süreçtir. Stratejik karar alma aşamasında sıklıkla kullanılan tekniklerden olan öngörü hem firmalar hem de hükümetler açısından oldukça önemlidir. Çünkü gelecekte yaşanabilecek belirsizliklerin önceden tahmini güvenli karar alma mekanizmasının işletilebilmesi için hayati bir öneme sahiptir. Öngörü mekanizması pek çok farklı disiplinde önemli bir yere sahiptir ayrıca ekonometrik verilerin tahmininde de büyük önem taşımakta ve yaygın biçimde kullanılmaktadır.

R programlama dili de istatistiksel hesaplamalar, büyük veri analizi ve bilimsel araştırmalarda verilerin temizlenmesi, analiz edilmesi, görselleştirilmesi ve faydalı bilgi çıkarımının yapılabilmesi için istatistikçiler, veri analistleri, araştırmacılar tarafından sıklıkla tercih edilen bir programlama dilidir. Dünya çapında pek çok iş analisti ve veri bilimci kurumlar için temel araçlardan birine dönüşen R programlama dilini finans, e-ticaret, sağlık, ekonomi gibi pek çok alanda kullanmaktadır.

Bu çalışma kapsamında ülkelerin ekonomik kalkınmalarında büyük önem taşıyan ihracat verileri incelenmiştir. İhracat verilerinin tahmini için Türkiye İstatistik Kurumu ve Merkez Bankası istatistiklerinden derlenen veri ambarı üzerinde, istatistiksel tahmin ve analizlerde sıklıkla tercih edilen R programı kullanılarak; geliştirilen farklı tahmin algoritmalarının performansları karşılaştırılmıştır. Çalışma kapsamında literatür taraması sonucunda sıklıkla kullanıldığı görülen üç farklı algoritma, performans karşılaştırması için tercih edilmiştir. Bu algoritmalar yapay sinir ağları, regresyon analizi ve zaman serisi

analizi teknikleridir. Oluşturulan veri seti %80 ve %20 oranında eğitim ve test verisi olarak ayrılmıştır. R programında geliştirilen algoritmalar eğitim veri üzerinde eğitilerek daha sonra test verisi üzerinde denenmiştir. Bu aşamada hesaplanan istatistiksel hata oranları üzerinden, algoritmaların performansları karşılaştırılmış ve en başarılı tahmin performansı gösteren algoritma belirlenmiştir. Çalışma bu yönüyle ekonometrik bir analizden ziyade istatistiksel bir programla dili olan R yazılımında geliştirilen farklı algoritmaların tahmin performanslarının karşılaştırılmasını amaçlamaktadır.

Bu amaçla çalışma kapsamında öncelikli olarak üzerinde çalışılacak veri setinin nitelikleri tanıtılmıştır. Daha sonra dış ticaret ve ihracat kavramlarından bahsedilerek dünyada ve ülkemizde dış ticaret rakamları verilmiş ayrıca ülkemiz özelinde ihracat rakamları da sunulmuştur. Ek olarak ihracat performansını etkileyen faktörler incelenmiştir. Çalışmanın ikinci bölümünde veri ambarı ve klasik veri tahmin teknikleri tanıtıldıktan sonra yapay sinir ağı tekniği detaylı olarak incelenmiştir.

Araştırma kapsamında öncelikle en iyi performansı gösteren yapay sinir ağına erişmek için birden fazla yapay sinir ağı test edilmiştir. Bu amaçla en iyi performansa sahip yapay sinir ağını belirleyebilmek için (4-2), (5-3), (6-4), (6-5), (8-3), (8-5), (5-4-3), (3-6-7), (4-5-8) gibi farklı katman ve eleman sayısına sahip ağ topolojilerinin hata oranları karşılaştırılmıştır. Yapay sinir ağı tekniğinde tahmin başarısının ölçülmesi için literatürde geçen MSE ve RMSE değerleri kontrol edilerek en düşük hata oranlarına sahip (Calp, 2017: 82; Bayır, 2006: 102; Karahan, 2011: 113; Gandomi ve Roke; 2015: 66) ağ topolojisi en başarılı olarak belirlenmiştir. Bu bağlamda geliştirilen yapay sinir ağlarına ait hata oranları arasında çok büyük farklılıklar olmamakla birlikte hata oranı en düşük yapay sinir ağının (5,3) ağ topolojisinde olduğu görülmüştür. Böylece klasik istatistiksel tahmin yöntemleri olan regresyon ve zaman serisi analizleriyle karşılaştırılacak olan ağ topolojisi (5,3) olarak belirlenmiştir. Ayrıca bağımsız değişkenlerin bağımlı değişken tahmini üzerindeki önemini belirleyen bir algoritma kullanılarak değişkenlerin önem seviyeleri incelenmiştir. Buna göre ihracat tutarı verisinin tahmini için en yüksek önem düzeyine sahip bağımsız değişkenin ihracat endeksi olduğu görülmüştür. İkinci seviyede önem değerine sahip değişkenlerin ise dolar alış, teknoloji endeksi ve üretim endeksi olduğu görülmüştür. İhracat tutarı verisinin tahmininde sınai kapanış

değerinin ise en düşük önem seviyesine sahip bağımsız değişken olduğu görülmüştür.

Uygulamanın ikinci aşamasında R programında ihracat tutarı verisinin tahmini için regresyon algoritması geliştirilmiştir. Regresyon tekniğinin sonuçlarına göre oluşturulan modelde; parametrelerin anlamlılık düzeyleri incelenmiş ve yapay sinir ağı algoritmasındaki önem seviyeleriyle benzer biçimde, sınai kapanış değeri regresyon modeli için anlamlı bulunmamıştır. Bu nedenle sınai kapanış değeri modelden çıkarılarak nihai regresyon modeli belirlenmiştir. Regresyon ve yapay sinir ağı teknikleri hem hata değerlerinden hem de tahmin değerleri grafiksel olarak incelenmiş ve yapay sinir ağının daha başarılı sonuçlar verdiği görülmüştür.

Uygulamanın son aşamasında ise zaman serisi tekniği ile veri tahmini yapılmıştır. Zaman serisi analizinin gerçekleştirilebilmesi için gereken varsayımlar sağlandıktan sonra naive bayes ve birden fazla arima modeli test edilerek performansları karşılaştırılmıştır. Zaman serisi tekniklerinden eldeki veri seti için ARIMA(1,0,0)(2,0,0) modelinin en iyi performansa sahip model olduğu görülmüştür. Buna göre ARIMA(1,0,0)(2,0,0) modeli eğitim verisi üzerinden eğitilerek veri tahmin başarısı gözlemlenmiştir. Ayrıca naive bayes ve arima modellerine ait hata oranları da karşılaştırılmıştır. Bu karşılaştırma sonrasında ARIMA modelinin naive bayes yöntemine göre tahmin performansı açısından daha başarılı olduğu görülmüştür.

Araştırmanın son aşamasında ise algoritmik olarak geliştirilen üç modelin karşılaştırması yapılmıştır. Karşılaştırma işlemi MSE ve RMSE değerleri kullanılarak gerçekleştirilmiştir. Bu hata oranlarının seçilmesinde yine literatüre başvurularak sıklıkla tercih edilen hata oranları seçilmiştir. Buna göre; Bayır (2006), Calp (2017), Karahan (2011), Yaman (2019) ve Turaç (2020) çalışmalarında kullanılan performans ölçütlerinden MSE ve RMSE ölçütleri kullanılmıştır.

Yapay sinir ağı, regresyon analizi ve zaman serisi teknikleri içerisinde yapay sinir ağı tekniğinin en başarılı performansı gösterdiği tespit edilmiştir. Çalışmanın son bölümünde gerçekleşen değer ile yapay sinir ağı, regresyon ve zaman serisi ile elde edilen değerler karşılaştırmalı bir tablo ve grafik gösterimi olarak sunulmuştur. Buna göre tablo 7 ile verilen literatür taramasında sonuçlara benzer biçimde yapay sinir ağının tahmin performansı klasik istatistiksel tahmin tekniklerine oranla daha başarılı bulunmuştur. Bu doğrultuda en başarılı bulunan yöntem olan yapay sinir ağı

(5,3) modeli ile geleceğe yönelik veri tahmini ve gerçekleşen değerleri de Tablo 14 ile gösterilmiştir.

Tablo 14: Yapay Sinir Ağı (5,3) ile Tahmin Edilen Değerler

Yıl	Ay	Gerçekleşen İhracat Tutarı	YSA(5,3) Tahmin Edilen İhracat Tutarı
2021	1	15.004.032	14.890.412
	2	15.952.665	15.478.036
	3	18.955.875	17.977.890
	4	18.756.898	18.012.365
	5	16.468.407	17.684.236
	6	19.740.824	18.950.478
	7	16.358.082	17.628.456
	8	18.861.074	18.001.365
	9	20.716.583	19.897.214
	10	20.714.278	20.042.369
	11	21.455.371	20.874.365
	12	22.233.685	21.896.354

Sonuç olarak yapay sinir ağı tekniği klasik istatistik tekniklerden farklı olarak hem verinin özellikleriyle ilgili varsayımlara gerek duymayan hem de matematiksel model türetmeye gerek duymayan bir tekniktir. Yöntem veri içerisindeki desenleri öğrenerek veri tahmininde bulunmaktadır. Günümüz analiz dünyasında yapay sinir ağı tekniği pek çok farklı alanda kullanılan ve başarılı sonuçlar elde eden bir tekniktir.

Ülkemizde özellikle son birkaç yılda kullanımı yaygınlaşan ancak dünya literatüründe daha uzun süredir kullanılan yapay sinir ağı tekniğinin özellikle öngörü modellemesinde başarılı sonuçlar verdiği görülmektedir. Genellikle paket programlar kullanılarak gerçekleştirilen yapay sinir ağı öngörü modellemesinde R programında algoritma geliştirerek veri tahminine ülke literatüründe pek rastlanmamıştır. Bu nedenle çalışmanın ülkemizdeki literatüre katkı sağlayacağı düşünülmektedir.

KAYNAKÇA

- Aaby, N.E. ve Slater, S.F. (1989). Management Influences On Export Performance: a review of the empiricalliterature 1978-88. *International Marketing Review*. 6(4): 7-23.
- Abiodun, O.I., Jantan, A., Omolara, A.E., Dada, K.V., Mohamed, N.A. ve Humaira, A. (2018). State-Of-The-Art İn Artificial Neural Network Applications: A Survey. *Heliyon*. 4(2018): 1-41.
- Abraham, A. (2005). Artificial Neural Networks. Handbook Of Measuring System Design (901-908). John Wiley&Sons.
- Abrougui, K., Gabsi, K., Mercatoris, B., Khemis, C., Amami, R., ve Chehaibi, S. (2019). Prediction Of Organic Potato Yield Using Tillage Systems And Soil Properties By Artificial Neural Network (ANN) And Multiple Linear Regressions (MLR). *Soil and Tillage Research*. 190: 202-208.
- Aditian, A., Kubota, T. ve Shinohara, Y. (2018). Comparison Of GIS-Based Landslide Susceptibility Models Using Frequency Ratio, Logistic Regression, And Artificial Neural Network In A Tertiary Region Of Ambon, Indonesia. *Geomorphology*. 318: 101-111.
- Ahi, L. (2015). *Veri Madenciliği Yöntemleri İle Ana Harcama Gruplarının Paylarının Tahmini*. (Yayınlanmamış Yüksek Lisans Tezi). Ankara: Hacettepe Üniversitesi Fen Bilimleri Enstitüsü.
- Akay, H. (2021). *Uluslararası Ticarete Ürün Ve Fiyat Adaptasyonunun İhracat Performansına Etkisi: Konya İmalat Sanayinde Bir Uygulama*. (Yayınlanmamış Yüksek Lisans Tezi). Konya: KTO Karatay Üniversitesi Lisansüstü Eğitim Enstitüsü.
- Akbilgiç, O. (2011), *Hibrit Radyal Tabanlı Fonksiyon Ağları İle Değişken Seçimi ve Tahminleme: Menkul Kıymet Yatırım Kararlarına İlişkin Bir Uygulama*. (Yayınlanmamış Doktora Tezi). İstanbul: İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.
- Akdağ, M. (2015). *Box Jenkins Ve Yapay Sinir Ağı Modelleri İle Enflasyon Tahmini*. (Yayınlanmamış Yüksek Lisans Tezi). Erzurum: Atatürk Üniversitesi Fen Bilimleri Enstitüsü.
- Aktaş, R., Doğanay, M. ve Yıldız, B. (2003). Mali Başarısızlığın Öngörülmesi: İstatistiksel Yöntemler ve Yapay Sinir Ağı Karşılaştırması. *Ankara Üniversitesi SBF Dergisi*, 58(4): 1-24.
- Akyüz, H. E. (2018). Vektör otoregresyon (VAR) modeli ile iklimsel değişkenlerin istatistiksel analizi. *International Journal of Engineering Research and Development*, 10(2), 183-192.

- Al-Bayati, O. A. S. (2019). *Using Artificial Neural Network With Comparative Analysis Of Different Techniques For The Classification Of Sentiment Analysis*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Altınbaş Üniversitesi.
- Almahmud, B. (2019). *Yapay Sinir Ağı Ve Box-Jenkins Modeli İle Yazıcı Sarf Malzemeler Verilerinin Tahmini Irak Örneği*. (Yayınlanmamış Yüksek Lisans Tezi). Isparta: Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü.
- Arı, A. ve Berberler, M. E. (2017). Yapay Sinir Ağları İle Tahmin Ve Sınıflandırma Problemlerinin Çözümü İçin Arayüz Tasarımı. *Acta Infologica*. 1(2): 55-73.
- Ariyachandra, T. ve Watson, H. (2010). Key Organizational Factors In Data Warehouse Architecture Selection. *Decision Support Systems*. 49(2): 200-212.
- Arslan, İ. (2017). *R İle İstatistiksel Programlama*. İstanbul: Pusula Yayıncılık.
- Aşıkgil, M. (2012). *Conceptual Quantity Modeling Of Single Span Highway Bridges By Regression, Neural Networks And Case Based Reasoning Methods* (Yayınlanmamış Yüksek Lisans Tezi). Ankara: ODTÜ Fen Bilimleri Enstitüsü.
- Aşkın, D., İskender, İ. ve Mamızadeh, A. (2011). Farklı Yapay Sinir Ağları Yöntemlerini Kullanarak Kuru Tip Transformatör Sargısının Termal Analizi. *Gazi Üniv. Müh. Mim. Fak. Der.* 26(4): 905-913.
- Ataseven, B. (2013). Yapay Sinir Ağları İle Öngörü Modellemesi. *Öneri Dergisi*. 10(39): 101-115.
- Ballı, M. T. (2014). *Yapay Sinir Ağları ile Talep Tahmini ve Gıda Sektöründe Uygulanması*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Bayır, F. (2006). *Yapay Sinir Ağları ve Tahmin Modellemesi Üzerine Bir Uygulama* (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.
- Bishop, C. M. (1995). *Neural Networks For Pattern Recognition*. USA: Oxford University Press.
- Borsa İstanbul (BİST). <https://www.borsaistanbul.com/tr/sayfa/340/kapanis-seansi> (Erişim Tarihi: 15.07.2022)
- Bozdağ, H. (2011). *Box-Jenkins Ve Yapay Sinir Ağı Yöntemleri İle Havalimanı Yolcu Talebi Öngörülenmesi: Antalya Havalimanı Örneği*. (Yayınlanmamış Yüksek Lisans Tezi). Isparta: Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü.
- Brohman, J. (1996). New Directions in Tourismfor Third World Development. *Annals of Tourism Research*. 23(1): 48-70.

- Cabral, A.F.G. (2021). *Data Profiling in Cloud Migration*. (Yayınlanmamış Yüksek Lisans Tezi). Potugal: NOVA Information Management School.
- Calp M. H. (2017). *Yazılım Projeleri İçin Yapay Zekâ Tabanlı Risk Yönetimi*. (Yayınlanmamış Doktora Tezi). Ankara: Gazi Üniversitesi Bilişim Enstitüsü.
- Calp, M. H. (2019). İşletmeler İçin Personel Yemek Talep Miktarının Yapay Sinir Ağları Kullanılarak Tahmin Edilmesi. *Politeknik Dergisi*, 22(3): 675-686.
- Can, Ş. ve Gerşil, M. (2018). Manisa pamuk fiyatlarının zaman serisi analizi ve yapay sinir ağı teknikleri ile tahminlenmesi ve tahmin performanslarının karşılaştırılması. *Yönetim ve Ekonomi: Celal Bayar Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 25(3): 1017-1031.
- Cansız Ö.F., Erginer İ. ve Doğru E. (2021) Amerika’da Meydana Gelen Trafik Kazalarının Yapay Sinir Ağları ve Çok Değişkenli Regresyon Yöntemleriyle Tahmini. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. 4(3): 342-354.
- Cesur, F. ve Kozhan, S. (2020). İmalat Sanayisine Kısa Bir Bakış. *Sosyal Bilimler Araştırma Dergisi*. 9(3): 170-179.
- Chatterjee, S. ve Hadi, A. S. (2015). *Regression Analysis By Example*. USA: John Wiley&Sons.
- Co, H.C. ve Boosarawongse, R. (2007). Forecasting Thailand Rice Export: Statistical Techniques vs. Artificial Neural Networks. *Computers & Industrial Engineering*. 53: 610-27.
- Çancı, M., Önden, İ., Çakmak, E., Gürel, Ö. ve Tuzla, H. (2015). *İstanbul’da Deniz Ulaşımının Geleceğinin Değerlendirilmesi*. İstanbul: Okan Üniversitesi İktisadi ve İdari Bilimler Fakültesi.
- Çavuşoğlu, T. (2021). *Yapay Sinir Ağları İle Türkiye Ekonomisindeki Doğrudan Yabancı Sermaye Yatırımları*. (Yüksek Lisans Tezi). Karabük Üniversitesi.
- Çelik, Ş. ve Köleoğlu, N. (2022). Trend analizi ve yapay sinir ağları: Tarımda bir uygulaması. *Journal of Awareness*. 7(1): 39-46.
- Çetin, M., Uğur, A. ve Bayzan, Ş. (2006), İleri Beslemeli Yapay Sinir Ağlarında Backpropagation (Geriye Yayılım) Algoritmasının Sezgisel Yaklaşımı. *Akademik Bilişim 2006*. Düzenleyen Pamukkale Üniversitesi. Denizli. 9-11 Şubat 2006,
- Çınar, U.K. (2018). <https://www.veribilimiokulu.com/yapay-sinir-aglari/> (01.01.2022)
- Çoban, F. ve Demir, L. (2021). Yapay Sinir Ağları ve Destek Vektör Regresyonu ile Talep Tahmini: Gıda İşletmesinde Bir Uygulama. *DEUFMD*. 23(67): 327-338.

Çot, E. (2019). *Yapay Sinir Ağı Tekniği Kullanılarak Polipropilen Bcf İpliklerinin Uzama, Mukavemet Ve Kıvrımlılık Değerlerinin Tahminlemesi: Tekstil Sektöründe Bir Uygulama*. (Yayınlanmamış Yüksek Lisans Tezi). Osmaniye: Osmaniye Korkut Ata Üniversitesi Sosyal Bilimler Enstitüsü.

Dayı, F. (2012). *Hisse Senedi Getirilerinin Tahmininde Yapay Sinir Ağı Modeli Kullanımı: İMKD'de Bir Uygulama*. (Yayınlanmamış Yüksek Lisans Tezi). Gaziantep: Gaziantep Üniversitesi Sosyal Bilimler Enstitüsü.

Deliçay, M. (2015). *Dünyada ve Türkiye’de Dış Ticareti Kolaylaştırmaya Yönelik Ulusal Koordinasyon Çalışmaları*. Kalkınma Bakanlığı, İktisadi Sektörler ve Koordinasyon Genel Müdürlüğü

Delvin.D. Hawley, J.D. Johson ve D. Raina, (1990). Artificial Neural Systems: A new tool for Finacial Decision Making. *Financial Anaylyst Journal*. 46(6): 63-72.

Dey, D. ve Kumar, S. (2013). Data Quality Of Query Results With Generalized Selection Conditions. *Operations Research*. 61(1): 17–31.

Dias, M.M.,Tait, T.C., Menolli, A.L.A. ve Pacheco, R.C.S. (2008). Data Warehouse Architecture Through Viewpoint of Information System Architecture. *International Conference on Computational Intelligence for Modelling Control &Automation*. (ss. 7-12). doi: 10.1109/CIMCA.2008.129.

Dinçer, A. (2021). *Determinants Of Sectoral And Firm Size Export Performance: Empirical Evidence From The Turkish Manufacturing Industry*. (Yayınlanmamış Doktora Tezi). Ankara: Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü.

Doğan, O. (2012). *Talep Tahmininde Sinirsel Ağ Tabanlı Bulanık Mantık Yöntemi (Anfis) Kullanımı Ve Yalın Yapay Sinir Ağı Metodu İle Karşılaştırmalı Bir Uygulama (Yayınlanmamış Doktora Tezi)*. İzmir: Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü.

Dongare, A. D., Kharde, R. R., ve Kachare, A. D. (2012). Introduction To Artificial Neural Network. *International Journal of Engineering and Innovative Technology (IJEIT)*. 2(1): 189-194.

Doyle, E. (2001). Export-Output Causality And The Role Of Exports İn Irish Growth: 1950-1997. *International Economic Journal*. 15(3): 31-54.

Dölek, A. (2006). *Uluslararası Ticaret ve Türkiye Uygulamaları*. İstanbul: Arıkan Basım Yayın Dağıtım.

Duman, O. (2016). *Batı Anadolu Bölgesindeki Depremlerin Yapay Sinir Ağı Yöntemiyle Tahmini*. (Yayınlanmamış Yüksek Lisans Tezi). Gümüşhane: Gümüşhane Üniversitesi Sosyal Bilimler Enstitüsü.

Durgun, A. ve apık, E. (2018). Ar-Ge Harcamaları Ve Yüksek Teknolojili Ürün İhracatının Büyümeye Etkisi: Türkiye Örneđi. *Yönetim ve Ekonomi Araştırmaları Dergisi*. 16(4): 301-314.

Düzgün, R. ve Taşçı, H.M. (2014). Türk İşletmelerinin İhracat Performansını Belirleyen Faktörler: İSO-500 Üzerine Bir Uygulama. *Eskişehir Osmangazi Üniversitesi İktisadi ve İdari Bilimler Dergisi*. 9(3): 7-24.

Elmas, Ç. (2007). *Yapay Zekâ Uygulamaları*. Ankara: Seçkin Yayıncılık.

Elveren, E. (2009). *Genetik Algoritmali Yapay Sinir Ağları Kullanılarak Tüberküloz Hastalığının Teşhisi*. (Yayınlanmamış Yüksek Lisans Tezi). Sakarya: Sakarya Üniversitesi Fen Bilimleri Enstitüsü.

Emeksiz Dünder, A. (2021). *İhracat Pazarlama Stratejisinin İhracat Performansı Üzerindeki Etkisi: Almanya'ya Otomotiv İhracatı Örneđi*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: TOBB Ekonomi ve Teknoloji Üniversitesi Sosyal Bilimler Enstitüsü.

Eser, T., Aksu, G. ve Güzeller, C. O. (2019). *R Programlama Dili ile Temel İstatistikler ve Raporlama*. Ankara: Pegem Akademi 2. Baskı.

Eşidir, K.A. (2021). *Yapay Sinir Ağları İle Metodu İle Türkiye Tavukçuluk Sektörü İhracat Tahmini Uygulaması*. (Yayınlanmamış Doktora Tezi). Elazığ: Fırat Üniversitesi Sosyal Bilimler Enstitüsü.

Gandomi H. ve Roke D. A. (2015). Assessment Of Artificial Neural Network And Genetic Programming As Predictive Tools. *Advances in Engineering Software*. 88: 63-72.

Genç Kavas, H. (2019). *Türkiye Enerji Sektörünün Stratejik Konumu Ve Yapay Sinir Ağı Modelleriyle Enerji Tüketiminin Tahmini*. (Yayınlanmamış Doktora Tezi). Sivas: Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü.

Gupta H. (1996). Selection of viewstomaterialize in a datawarehouse. In: Afrati F.,Kolaitis P. (eds) Database Theory — ICDT '97. *ICDT 1997. LectureNotes in ComputerScience*, vol 1186. Springer, Berlin, Heidelberg. https://doi.org/10.1007/3-540-62222-5_39.

Gupta, N. ve Jolly, S. (2021). Enhancing Data Quality at ETL Stage of Data Warehousing. *International Journal of Data Warehousing and Mining (IJDWM)*. 17(1): 74-91.

Gülçe, G. (2010). *Veri Ambarı Ve Veri Madenciliđi TeknikleriKullanılarak Öğrenci Karar Destek Sistemi Oluşturma*. (Yayınlanmamış Yüksek Lisans Tezi). Denizli: Pamukkale Üniversitesi Fen Bilimleri Enstitüsü.

Gültekin, S. U. (2017). *Veri Madenciliği: Yapay Sinir Ağı Ve Doğrusal Regresyon Yöntemleri İle Fiyat Tahmini*. (Yayınlanmamış Yüksek Lisans Tezi). Denizli: Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü.

Gündoğdu, S. (2021). Osteoporozla Bağlı Kifozlu Hastalara Uygulanan Egzersizlerin Oluşturduğu Denge Değişikliklerine İlişkin Veriler Kullanılarak Yapay Sinir Ağlarının Diğer Sınıflandırma Algoritmalarıyla Karşılaştırılması. *Iğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. 11(4): 2660-2672.

Gürbüzer, Y.E. (2019). *Uluslararası Ticaret Ve Emek Piyasaları*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Marmara Üniversitesi Sosyal Bilimler Enstitüsü.

Güven, E. T. A. (2021). İhracata Dayalı Büyüme Modeli: Türkiye Örneği (1980-2020). *Aksaray Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 13(1): 63-70.

Han, G., Sönmez, E.F., Avcı, S. ve Aladağ, Z. (2022). Uygun Normalizasyon Tekniği Ve Yapay Sinir Ağları Analizi İle Otomobil Satış Tahminlemesi. *İşletme Ekonomi ve Yönetim Araştırmaları Dergisi*. 5(1):19-45.

Hanke, J. E. and Wichern, D. W. (2005). *Business Forecasting, 8th Edition*. USA: Pearson Prentice Hall.

Hassanipour, S., Ghaem, H., Arab-Zozani, M., Seif, M., Fararouei, M., Abdzadeh, E., Sabetian, G. ve Paydar, S. (2019). Comparison Of Artificial Neural Network And Logistic Regression Models For Prediction Of Outcomes İn Trauma Patients: A Systematic Review And Meta-Analysis. *Injury*. 50(2): 244-250.

Haykin, S. (1998). *Neural Networks: A Comprehensive Foundation Seconf Ed*. New Jersey: Prentice Hall.

Helpman, E. ve Krugman, P. R. (1985). *Market Structure And Foreign Trade: Increasing Returns, Imperfect Competition, And The International Economy*. USA: MIT Press.

Hosseinzadeh, A., Baziar, M., Alidadi, H., Zhou, J. L., Altaee, A., Najafpoor, A. A., & Jafarpour, S. (2020). Application Of Artificial Neural Network And Multiple Linear Regression İn Modeling Nutrient Recovery İn Vermicompost Under Different Conditions. *Bioresource Technology*. 303: 1-8.

Hultman, M., Robson, M. J. ve Katsikeas, C. S. (2009). Export Product Strategy Fit and Performance: An Empirical Investigation. *Journal of International Marketing*. 17(4): 1-23.

Hüsemann, B., Lechtenbörger, J. ve Vossen, G. (2000). Conceptual Data Warehouse Design (Pp. 6-1). Universität Münster. Angewandte Mathematik und Informatik.

Inmon, W.H. (2002). *Building the Data Warehouse 3rd. ed.* ISBN: 0-471-08130-2. Canada: Wiley.

Intriligator, M. Bodkin, R. ve Hsiao, C. (1996). *Econometric Models, Techniques and Applications, Second Edit.* New Jersey: Prentice Hall Inc.

Iqbal, A. ve Aftab, S. (2019). A Feed-Forward and Pattern Recognition ANN Model for Network Intrusion Detection. *International Journal of Computer Network & Information Security*. 4: 19-25.

İpek, H. (2015). *Uluslararası Ticaret, Türkiye –Türkmenistan İlişkileri Ve Taşımacılık Uygulamaları.* (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Maltepe Üniversitesi Sosyal Bilimler Enstitüsü.

Jain, A. K., Mao, J. ve Mohiuddin, K. M. (1996). Artificial Neural Networks: A tutorial. *Computer*. (3): 31-44.

Jannot, A.-S., Zapletal, E., Avillach, P., Mamzer, M.-F., Burgun, A. ve Degoulet, P. (2017). The Georges Pompidou University Hospital Clinical Data Warehouse: A 8-Years Follow-Upexperience. *International Journal of MedicalInformatics*. 102: 21-28.

Karaçor, A. G. (2017). *Artificial Neural Network Based Decisive Prediction Models On High Frequency Financial Data.* (Yayınlanmamış Doktora Tezi). İstanbul: Atılım Üniversitesi Sosyal Bilimler Enstitüsü.

Karahan, M. (2011). İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu İle Ürün Talep Tahmini Uygulaması. Selçuk Üniversitesi Sosyal Bilimler Enstitüsü.

Karakan, G. ve Koç, T. (2008). Teknoloji Tahmin Yöntemleri Ve Beyaz Eşya Sektöründe Bir Uygulama. *Endüstri Mühendisliği Dergisi*. 20(1).

Karakuş, A. (2015). *Regresyon Analizi Ve Yapay Sinir Ağı Kullanılarak Stok Market İş Döngüsü Tahmini.* (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Bahçeşehir Üniversitesi Endüstri Mühendisliği Bilimi Enstitüsü.

Kavuncuoğlu, H., Kavuncuoğlu, E., Karatas, S. M., Benli, B., Sagdic, O. ve Yalcin, H. (2018). Prediction Of The Antimicrobial Activity Of Walnut (Juglans Regia L.) Kernel Aqueous Extracts Using Artificial Neural Network And Multiple Linear Regression. *Journal Of Microbiological Methods*. 148: 78-86.

Kayaalp, G. T., Güney, M. Ç. ve Cebeci, Z. (2015). Çoklu Doğrusal Regresyon Modelinde Değişken Seçiminin Zoote kniye Uygulanışı. *Çukurova Üniversitesi Ziraat Fakültesi Dergisi*. 30(1): 1-8.

Kayakuş, M. ve Terzioğlu, M. (2021). Yapay Sinir Ağları ve Çoklu Doğrusal Regresyon Kullanarak Emeklilik Fonu Net Varlık Değerlerinin Tahmin Edilmesi. *Bilişim Teknolojileri Dergisi*. 14(1): 95-103.

- Keskin, L. (2020). *Yağış – Akış İlişkisinin Yapay Sinir Ağları Ve Otoregresif Hareketli Ortalamalar Modelleri İle Tahmini*. (Yayınlanmamış Yüksek Lisans Tezi). İskenderun: İskenderun Teknik Üniversitesi Mühendislik Ve Fen Bilimleri Enstitüsü.
- Keskin Benli, Y. ve Yıldız, A. (2014). Altın Fiyatının Zaman Serisi Yöntemleri Ve Yapay Sinir Ağları İle Öngörüsü. *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*. (42): 213-224.
- Khair, U., Fahmi, H., Al Hakim, S. ve Rahim, R. (2017). Forecasting Error Calculation With Mean Absolute Deviation And Mean Absolute Percentage Error. *In Journal of Physics: Conference Series* (Vol. 930, No. 1, p. 012002). IOP Publishing.
- Khosravi, A. K. R. M. L. P. J., Koury, R. N. N., Machado, L., ve Pabon, J. J. G. (2018). Prediction Of Wind Speed And Wind Direction Using Artificial Neural Network, Support Vector Regression And Adaptive Neuro-Fuzzy Inference System. *Sustainable Energy Technologies and Assessments*. 25: 146-160.
- Kılıç, S. (2013). Doğrusal Regresyon Analizi. *Journal of Mood Disorders*. 3(2): 90-92.
- Kırbaş, İ. (2018). İstatistiksel Metotlar Ve Yapay Sinir Ağları Kullanarak Kısa Dönem Çok Adımlı Rüzgâr Hızı Tahmini. *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*. 22 (1): 25-39.
- Koç, E. , Şenel, M. C. ve Kaya, K. (2017). Türkiye’de Ekonomik Göstergeler - İmalat Sanayi Kapasite Kullanım Oranı. *Mühendis ve Makine*. 58(689): 1-22.
- Kumar, A. (2016). Artificial Neural Networks for Data Mining, <http://studyres.com/doc/690730/artificial-neural-networks-for-data-mining> (25.12.2021).
- Kurt, F. E. ve Senal, S. (2018). Borsa İstanbul’da Kote Bireysel Emeklilik, Hayat Ve Hayat-Dışı Sigorta Şirketlerinin Hisse Senedi Fiyat Tahmininde Box-Jenkins Yöntemi. *Muhasebe ve Finansman Dergisi*. 80: 233-252.
- Kutlu, A. B. (2016). *Dinamik Veri Ambarı Tasarımı Ve Bir Uygulama Örneği* (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Beykent Üniversitesi Fen Bilimleri Enstitüsü.
- Kutlu, D. ve Badur, Y. (2009). Yapay Sinir Ağları ile Borsa Endeksi Tahmini. *Yönetim Dergisi*. 20(63): 25-40.
- Lippmann, R. P. (1988). An Introduction to Computing with Neural Nets. Artificial Neural Networks. *Theoretical Concepts*. 209(1): 36-54.
- Liu, Q., Feng, G., Tayi, G. K. ve Tian, J. (2019). Managing DataQuality of the Data Warehouse: A Chance-Constrained Programming Approach. *Information Systems Frontiers*. 23: 375–38.

- Lourakis, M. I. (2005). A Brief Description Of The Levenberg-Marquardt Algorithm Implemented By Levmar. *Foundation of Research and Technology*. 4(1): 1-6.
- Maden, H.S. ve Özcan, Y. (2021). Türkiye'nin Gıda Ticareti Ve Açıklanmış Karşılaştırmalı Üstünlükler Modeli: Jelatin Pazarı Örneği. *Stratejik ve Sosyal Araştırmalar Dergisi*. 5(1): 45-66.
- Majocchia, A., Bacchiocchib, E. ve Mayrhofer, U. (2005). Firm Size, Business Experience and Export Intensity in SMEs: A Longitudinal Approach to Complex Relationship. *International Business Review*. 14: 719- 738.
- Makridakis, S., Wheelwright, S.C. ve Hyndman, R.J. (1998). *Forecasting: Methods And Applications, 3rd Edition*. USA: John Wiley&Sons.
- Manjunath T.N., Ravindra S.H. ve Ravikumar, G.K. (2010). Analysis of Data QualityAspects in Data Warehouse Systems. *International Journal of Computer Scienceand Information Technologies*. 2 (1): 477-485.
- Martino, J. P. (1993). *Technological Forecasting for Decision Making, 3rd ed*. New York : McGraw-Hill.
- Medsker L. R., Jain L. C., (2001). *Recurrent Neural Networks Design and Applications*. CRC Press.
- Menolli, A. L. A. ve Dias, M. M. (2006). A Data Warehouse Architecture In Layers For Science And Technology. *In Proceedings Of The Eighteenth International Conference On Software Engineering & Knowledge Engineering* (ss. 162-165). SanFrancisco, California.
- Mohammadi, F., Pourzamani, H., Karimi, H., Mohammadi, M., Mohammadi, M., Ardalan, N., Khoshravesh, R. Pooresmaeil, H., Shahabi, S., Sabahi, M., Miryonesi, F. S., Nafaji, M., Yavari, Z., Mohammadi, F., Teiri, H. ve Jannati, M. (2021). Artificial Neural Network And Logistic Regression Modelling To Characterize COVID-19 Infected Patients İn Local Areas Of Iran. *Biomedical Journal*. 44(3): 304-316.
- Muhlemann, A., Oakland, J. ve Lockyer, K. (1994). *Productionand Operations Management, 6. Edition*. London: Pitman Publishing, University of Broadford.
- Muzır, E. (2011). *Basel II Düzenlemeleri Doğrultusunda Kredi Riski Analizi Ve Ölçümü: Geleneksel Ekonometrik Modellerin Yapay Sinir Ağı Ve Mars Modelleriyle Karşılaştırılmasına Yönelik Ampirik Bir Çalışma*. (Yayınlanmamış Doktora Tezi). İstanbul: İstanbul Üniversitesi Sosyal Bilimler Enstitüsü.
- Nainggolan, R., Perangin-angin, R., Simarmata, E., & Tarigan, A. F. (2019, November). Improved The Performance Of The K-Means Cluster Using The Sum Of Squared Error (SSE) Optimized By Using The Elbow Method. *In Journal of Physics: Conference Series* (s. 012015).

Nhu, V. H., Shirzadi, A., Shahabi, H., Singh, S. K., Al-Ansari, N., Clague, J. J., Jaafari, A., Chen, W., Miraki, S., Dou, J., Luu, C., Górski, K., Pham, B.T., Nguyen, H. D., Ahmad, B. B. (2020). Shallow Landslide Susceptibility Mapping: A Comparison Between Logistic Model Tree, Logistic Regression, Naïve Bayes Tree, Artificial Neural Network, And Support Vector Machine Algorithms. *International Journal Of Environmental Research And Public Health*. 17(8): 2749.

Önder, E.ve Hasgöl Kuvat, Ö. (2009). Yabancı Ziyaretçi Sayısının Tahmininde Box Jenkins Modeli, Winters Yöntemi Ve Yapay Sinir Ağlarıyla Zaman Serisi Analizi (Time Series Analysis With Using Box Jenkins Models And Artificial Neural Network For Forecasting Number Of Foreign Visitors). *Istanbul University, Business Economy Institute Journal of Management*. 62: 62-83.

Örs, O. (2017). *Candidate Selection Process For Polymer Gel Application By Using Artificial Neural Networks*. (Yayınlanmamış Doktora Tezi). Ankara: ODTÜ Fen Bilimleri Enstitüsü.

Özçalıcı, M. ve Ayriçay, Y. (2016). Bilgi İşlemsel Zekâ Yöntemleri ile Hisse Senedi Fiyat Tahmini: BİST Uygulaması. *Pamukkale Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*. Ek(1): 274-298.

Özkan, G. ve Yılmaz, H. (2017). Ar-Ge Harcamalarının Yüksek Teknoloji Ürün İhracatı Ve Kişi Başı Gelir Üzerindeki Etkileri: 12 Ab Ülkesi Ve Türkiye İçin Uygulama (1996-2015). *Bilgi Ekonomisi ve Yönetimi Dergisi*. 12(1): 1-12.

Özkan, O., Kınacı, C. ve Sağıroğlu, Ş. (2011). Çözünmüş Oksijen Değişiminin Yapay Sinir Ağları İle Belirlenmesi: Kızılırmak Nehri Örneği. *İtüdergisi/D*. 5(3): 30-38.

Özkan, T. (2019). *Patlatma Kaynaklı Yer Sarsıntısının Farklı Regresyon Modelleri Ve Yapay Sinir Ağı İle Kestirimi*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: İTÜ Fen Bilimleri Enstitüsü.

Özkan, Y., Sarer-Yürekli, B. ve Suner, A. (2021). Diyabet Tanısının Tahminlenmesinde Denetimli Makine Öğrenme Algoritmalarının Performans Karşılaştırması. *Gümüşhane Üniversitesi Fen Bilimleri Dergisi*. 12(1): 211-226

Özmen-Akyol, S. (2022). Estimating Breast Cancer Class Using Artificial Neural Network and Logistic Regression Methods. *ESTUDAM Bilişim Dergisi*. 3(1): 26-31.

Öztemel E. (2003). *Yapay Sinir Ağları, (1. Baskı)*. İstanbul: Papatya Yayıncılık.

Öztemiz, H. (2021). Türkiye İhracat Birim Değer Endeksi ve İhracat Miktar Endeksinin Markov Süreçleri ile Uzun Dönem Analizi. *Gümrük ve Ticaret Dergisi*. 8(25): 50-61.

Patton, M.Q. (2014). Nitel Araştırma ve Değerlendirme Yöntemleri, 3. Baskıdan Çeviri, ISBN 978-605-364-933-5, Pegem Akademi, s. 4-7.

Polat, Ö. O. (2019). *Dış Ticaret İşletmelerinin Finansal Türev Ürün Kullanımlarının Firma Performansı Üzerindeki Etkileri: Marmara Bölgesi Araştırması* (Yayınlanmamış Doktora Tezi). İstanbul: Beykent Üniversitesi Sosyal Bilimler Enstitüsü.

Polat, Ö. (2009). Türkiye'nin Dış Ticaret Verilerinin Öngösüründe Yapay Sinir Ağları ve Box-Jenkins Modellerinin Karşılaştırmalı Analizi. (Yayınlanmamış Doktora Tezi). Atatürk Üniversitesi, Erzurum.

Polykretis, C. ve Chalkias, C. (2018). Comparison And Evaluation Of Landslide Susceptibility Maps Obtained From Weight Of Evidence, Logistic Regression, And Artificial Neural Network Models. *Natural Hazards*. 93(1): 249-274.

Ponniah, P. (2001). *Data Warehouse Fundamentals / A Comprehensive Guide for IT Professionals*. USA: Wiley Publications.

Ranganathan, A. (2004). The Levenberg-Marquardt Algorithm. *Tutorial On LM Algorithm*. 11(1): 101-110.

Rifaie, M., Kianmehr, K., Alhajj, R. ve Ridley, M.J. (2008). Data Warehouse Architecture And Design. *2008 IEEE International Conference on Information Reuse and Integration*. (pp. 58-63).

Robinson, R., Balassa, B., Wonnacott, P. Bertrand, T. J. and Allais, M. (2020). International Trade. Encyclopedia Britannica. <https://www.britannica.com/topic/international-trade>, (01.05.2022).

Sağıroğlu, Ş., Beşdok E. ve Erler, M. (2003), *Mühendislikte Yapay Zeka Uygulamaları-I Yapay Sinir Ağları*. Kayseri: Ufuk Kitap Kırtasiye Yayıncılık Tic. Ltd. Şti.

Sakarya, Ş. (2009). İhracat Yapan İşletmelerin Finansman Kaynaklarının Belirlenmesine Yönelik Bir Alan Araştırması. *The Journal of Accounting and Finance*. 42: 117-134.

Salahoğlu, P. H. (2019). *Kurumsallaşma Ve İhracat Performansı İlişkisi: Türkiye Örneği*. (Yayınlanmamış Doktora Tezi). İstanbul: İstanbul Okan Üniversitesi Sosyal Bilimler Enstitüsü.

Saray, U. (2012). *Rüzgâr Potansiyelinin Yapay Sinir Ağlarıyla Analizi ve Uygulaması*. (Yayınlanmamış Yüksek Lisans Tezi). Kırıkkale: Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü.

- Sarı, M. (2016). *Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması*. (Yayınlanmamış Yüksek Lisans Tezi). Sakarya: Sakarya Üniversitesi, Fen Bilimleri Enstitüsü.
- Saygılıoğlu Erdoğan, A. (2016). Türkiye'nin İhracatını Etkileyen Faktörler: Çoklu Regresyon Analizi. *Sosyal Bilimler Araştırma Dergisi*. 5(2): 1-8.
- Saygılıoğlu, N. ve Akçin, R. (2018). *Dış Ticaret ve Gümrük: Teori, Mevzuat ve Uygulama*. Ankara: Cem Ofset.
- Sebaa, A., Chikh, F., Nouicer, A. ve Tari, A. (2018). Medical Big Data Warehouse: Architecture And System Design, A Case Study: Improving Health Care Resources Distribution. *Journal of Medical Systems*. 42(4): 59.
- Seddighi, H. R., Lawyer K.A. ve Katos, A.V. (2000). *Econometrics: A Pratical Approach*. London: Routlenge Taylor and Francis Group.
- Serttaş, Z. (2011). *Türkiye' de Perakende Sektöründe Talebi Etkileyen Etmenler ve Yapay Sinir Ağlarıyla Talep Tahmini Uygulaması*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- Sevim, A. (2006). *Applications Of Forecasting Techniques On Turkish Foreign Trade Data*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Marmara Üniversitesi Sosyal Bilimler Enstitüsü.
- Sevüktekin, M. ve Çınar, M. (2014). *Ekonometrik Zaman Serisi Analizi Eviews Uygulamalı*. İstanbul: Dora yayıncılık.
- Seyoum, B. (2009). *Export-Import Theory, Practices, and Procedures* NewYork: Routledge Yayınevi.
- Shams, S. R., Jahani, A., Moeinaddini, M. ve Khorasani, N. (2020). Air Carbon Monoxide Forecasting Using An Artificial Neural Network İn Comparison With Multiple Regression. *Modeling Earth Systems and Environment*. 6(3): 1467-1475.
- Sharma, A. ve Chopra, A. (2013). Artificial neural networks: Applications in management. *Journal of Business and Management*. 12(5): 32-40.
- Smyth, G. K. (2002). Non Linear Regression. *Encyclopedia Of Environmetrics*. 3: 1405-1411.
- Sohrabpour, V., Oghazi, P., Toorajipour, R. ve Nazarpour, A. (2021). Export Sales Forecasting Using Artificial İntelligence. *Technological Forecasting and Social Change*. 163: 1-10.
- Solmaz, AH. Tiren, Y. ve Özkaya, U. (2021). Kalp Hastalıklarının Tahmin Edilmesi Karşılaştırmalı Analiz. *1st International Conference on Applied Engineering and Natural Sciences*. 1-3 Kasım Konya.

- Song, Y., Rowen, W., Medsker, C. ve Ewen, E. (2001). An Analysis Of Many-To-Many Relationships Between Fact And Dimension Tables In Dimensional Modeling. In: Proceedings of International Workshop on Design and Management of Data Warehouses (DMDW'01), Zurich, Switzerland, 6.1-6.13.
- Sousa, C.M.P., Martínez-Lopez, F.J. ve Coelho, F. (2008). The Determinants of Export ve F. Coelho: Performance: A Review of The Research in The Literature Between 1998 and 2005. *International Journal of Management Reviews*. 10(4): 343–374.
- Soysal, M. ve Ömürgönülşen, M. (2010). Türk Turizm Sektöründe Talep Tahmini Üzerine Bir Uygulama. *Anatolia: Turizm Araştırmaları Dergisi*. 21(1) Prof. Dr. Hasan Işın Dener Özel Sayısı: 128-136.
- Sönmez, O. ve Zengin, K. (2019). Yiyecek ve İçecek İşletmelerinde Talep Tahmini: Yapay Sinir Ağları ve Regresyon Yöntemleriyle Bir Karşılaştırma. *European Journal of Science and Technology*. (Special Issue): 302-308
- Sözgen, B. (2009). *Neural Network And Regression Models To Decide Whether Or Not To Bid For A Tender In Offshore Petroleum Platform Fabrication Industry*. (Yayınlanmamış Yüksek Lisans Tezi). Ankara: ODTÜ Fen Bilimleri Enstitüsü.
- Subaşı, A. ve Erdem, K. (2021). Hibrit Nanoakışkanların Özgül Isılarının Yapay Sinir Ağları İle Tahmin Edilmesi. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*. 37(1)Ç 377-388.
- Sungur, O. (2015). 2000 Sonrası Türkiye Ekonomisi: Büyüme, Enflasyon, İşsizlik, Borçlanma Ve Dış Ticarete Gelişmeler. *Toplum ve Demokrasi Dergisi*. 9(19): 243-270.
- Suzuki, K. (2011). *Artificial Neural Networks - Methodological Advances And Biomedical Applications*. Published by In Tech Intech
- Süygün, Z. (2021). *Yenilikçilik Kabiliyetinin İhracat Performansına Etkisinde Örgütsel Yeteneğin Aracılık Rolü: Mersin-Tarsus Organize Sanayi Bölgesi Örneği*. (Yayınlanmamış Yüksek Lisans Tezi). Mersin: Toros Üniversitesi Lisansüstü Eğitim Enstitüsü.
- Sykes, A. O. (1993). An Introduction to Regression Analysis. (Coase-Sandor Institute for Law & Economics Working Paper No. 20.
- Şahin, Y. (2020). *Gelecek Dönemlere Ait Türkiye Elektrik Tüketimi Tahmininde Yapay Sinir Ağları Modelinin Kullanılması*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Marmara Üniversitesi Sosyal Bilimler Enstitüsü.
- Şahin, Y. ve Yalçınkaya, S. (2021). *Bazı Polimerlerin Tribolojik Davranışlarının Tahmini Analizi*. İstanbul: Güven-Plus Grup A.Ş Yayınlar.

Şeker, A. (2018). *Teknolojik Ürün Ticareti Ve Ekonomik Büyüme İlişkisi*. (Yayınlanmamış Doktora Tezi). Yalova: Yalova Üniversitesi Sosyal Bilimler Enstitüsü.

Şenol, Ş. (2008). *Çıkarsamalı İstatistik*. Nobel Yayıncılık.

Şerbetli, A. (2008). *Makro Ekonomik Göstergelerin Banka Karlılığı Ve Sermaye / Aktif Getirisi Üzerindeki Etkisinin Yapay Sinir Ağları İle Test Edilmesi*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Marmara Üniversitesi Sosyal Bilimler Enstitüsü.

Şirin, S. M. (2018). *R İle Uygulamalı Analiz Yöntemleri 1-İstatistiğe Giriş ve Açıklayıcı Veri Analizi*. Ankara.

Tabar, M.E., Başara, A.C. ve Şişman, Y. (2021). Çoklu Regresyon ve Yapay Sinir Ağları ile Tokat İlinde Konut Değerleme Çalışması. *Türkiye Arazi Yönetimi Dergisi*. 3(1): 01-07.

Tepehan, T. (2011). *Türk Öğrencilerinin Pısa Başarılarının Yordanmasında Yapay Sinir Ağı Ve Lojistik Regresyon Modeli Performanslarının Karşılaştırılması*. (Yayınlanmamış Doktora Tezi). Ankara: Hacettepe Üniversitesi Sosyal Bilimler Enstitüsü.

Ter Braak, C. J. F. ve Looman, C. W. N. (1995). *Regression. In Data analysis in Community and Landscape Ecology*. UK: Cambridge University Press.

Theodoratos, D. and Sellis, T. (1997). Data Warehouse Conguration. Data Warehouse Configuration. *In Proceedings of the International Conference on Very Large Data Bases*. (ss. 126-135). Athens Greece, August 1997.

Tipi, İ. (2019). *Rekabetçi Bir Yaklaşımla İhracat Performansını Etkileyen Faktörlerin Belirlenmesi ISO-500 Üzerine Uygulamalı Bir Araştırma*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Marmara Üniversitesi Sosyal Bilimler Enstitüsü.

Toker, K. G. (2013). *Kanonik Korelasyon Analizi ile Sistem Tanıma*. (Yayınlanmamış Yüksek Lisans Tezi). Ankara: Hacettepe Üniversitesi Fen Bilimleri Enstitüsü.

Tolon, M. (2008). Tüketici Tatmini Verilerinin Analizi: Yapay Sinir Ağları Ve Regresyon Analizi Karşılaştırması. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. 10(2): 247-259.

Turaç, A. (2020). *Yapay Sinir Ağları İle Tahminleme: Türkiye'nin İhracatının Tahmini Üzerine Bir Uygulama*. (Yayınlanmamış Yüksek Lisans Tezi). Gebze: Gebze Teknik Üniversitesi Sosyal Bilimler Enstitüsü.

Tütek, H. ve Gümüsoğlu, Ş. (2011). *İşletme İstatistiği*. İstanbul: Beta Basım Yayın.

Ünal, A. (2018). *Veri Ambarı Oluşturmada Etl Ve Elt Yaklaşımlarının Kullanımı Ve Karşılaştırılması*. (Yayınlanmamış Yüksek Lisans Tezi). Ankara: Gazi Üniversitesi Fen Bilimleri Enstitüsü.

Ünvan, A. Y. ve Ergenç, C. (2022). Forecasting BIST 100 Index with Artificial Neural Networks and Regression Analysis. *BILTURK, The Journal of Economics and Related Studies*. 4(1): 20-32.

Vural, Y. (2008). Kredi Kartı için Yapay Sinir Ağları (YSA) Uygulaması. İstanbul.

Yağımlı, M. ve Ergin, H. (2017). Türkiye’de İş Kazalarının Üssel Düzeltme Metodu ile Tahmin Edilmesi. *Marmara Fen Bilimleri Dergisi*. 29(4): 118-123.

Yakut, E. (2012). *Veri Madenciliği Tekniklerinden C5.0 Algoritması Ve Destek Vektör Makineleri İle Yapay Sinir Ağlarının Sınıflandırma Başarılarının Karşılaştırılması: İmalat Sektöründe Bir Uygulama*. (Yayınlanmamış Doktora Tezi). Erzurum: Atatürk Üniversitesi Sosyal Bilimler Enstitüsü.

Yaman, B.(2019). *Türkiye’nin İhracat Değerlerinin Yapay Sinir Ağları İle Tahmini*. (Yayınlanmamış Yüksek Lisans Tezi). Antalya: Alaaddin Keykubat Üniversitesi Sosyal Bilimler Enstitüsü.

Yasin, M.G. (2013). *Turkey’s Short Term Hourly Electricity Demand Forecasting Using Artificial Neural Network*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: Bahçeşehir Üniversitesi Fen Bilimleri Enstitüsü.

Yavuz, S. ve Karabulut, T. (2016). Kanonik Korelasyon Analizi Metodu İle Birbirinin Devamı Olan Dersler Arasındaki İlişkinin İncelenmesi: İşletme Bölümü Örneği. *Kafkas University Journal of the Institute of Social Sciences*. 18: 459-476.

Yetgin, C. (2020). *Ülke İhracatının Geliştirilmesinde Genişbant İnternet Erişimi ve Kurumsal Kaynak Planlama Sistemlerinin Etkisi*. (Yayınlanmamış Doktora Tezi). İstanbul: İstanbul Ticaret Üniversitesi Dış Ticaret Enstitüsü.

Yıldırım, A. (2019). *Talep Tahmin Yöntemlerinin Karşılaştırmalı Analizi: Gıda Sektöründe Bir Uygulama*. (Yayınlanmamış Yüksek Lisans Tezi). İstanbul: İstanbul Kültür Üniversitesi Lisansüstü Eğitim Enstitüsü.

Yıldız, Ö. (2006). *Döviz Kuru Tahmininde Yapay Sinir Ağlarının Kullanılması, İşletme Anabilim Dalı*. (Yayınlanmamış Yüksek Lisans Tezi). Eskişehir: Osman Gazi Üniversitesi Sosyal Bilimler Enstitüsü.

Yılmaz, M. (2012). Jeodezik Nokta Hız Kestiriminde Yapay Sinir Ağlarının Kullanılabilirliği, Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü Yayınlanmamış Doktora Tezi, Afyonkarahisar

Yörübulut, S., Dogan, O., Erdugan, F. ve Yörübulut, S. (2019). Tahribatsız Yöntem Verileri Kullanılarak Yapay Sinir Ağı ve Regresyon Yöntemi ile Beton Basınç Dayanımının Tahmin Edilmesi. *International Journal of Engineering Research and Development*. 12(2): 769-776.

Yücel, A. (2006). *İhracat Pazarlaması Stratejilerinin Firma Performansı Üzerine Etkileri Hazır Giyim Firmaları Üzerine Bir Uygulama*. (Yayınlanmamış Tezi). Ankara: Ankara Üniversitesi, Sosyal Bilimler Enstitüsü.

Zhang, D., Lin, J., Peng, Q., Wang, D., Yang, T., Sorooshian, S., Liu, X. ve Zhuang, J. (2018). Modeling And Simulating Of Reservoir Operation Using The Artificial Neural Network. Support Vector Regression, Deep Learning Algorithm. *Journal of Hydrology*. 565: 720-736.

Zhang, T., Liu, Y., Rao, Y., Li, X., & Zhao, Q. (2020). Optimal Design Of Building Environment With Hybrid Genetic Algorithm, Artificial Neural Network, Multivariate Regression Analysis And Fuzzy Logic Controller. *Building and Environment*. 175: 106810.

Zilouchian, A. (2001). *Fundamentals Of Neural Networks. Intelligent Control Systems Using Soft Computing Methodologies*. CRC Press.

Zou, S. ve Stan, S. (1998). The Determinants Of Export Performance: A Review Of The Empirical Literature Between 1987 And 1997. *International Marketing Review*. 15(5). 333-356.

Xu, Y., Wang, L., Xu, B., Jiang, W., Deng, C., Ji, F. ve Xu, X. (2019). An Information Integration And Transmission Model Of Multisource Data For Product Quality And Safety. *Information Systems Frontiers*. 21(1): 191-212.

EK 1: R İle Geliştirilen Algoritmaların Kodları

```
library(MASS)
library(neuralnet)
library(nnet)
library(NeuralNetTools)
library(boot)
library(caret)
library(corrplot)
library(DataExplorer)
View(veri)
plot_str(veri)
#eksik veri kontrolü
eksik_veri <- apply(veri, 2, function(x) sum(is.na(x)))
eksik_veri
sapply(veri, class)
corrplot(cor(veri))
veri <- read.csv(file='C:/Users/sengul.can/Desktop/YSA-Döküman/veri.csv', head=TRUE,
sep=";", stringsAsFactors = FALSE)
maxValue <- apply(veri, 2, max)
minValue <- apply(veri, 2, min)
veri <- as.data.frame(scale(veri, center= minValue, scale=maxValue-minValue))
veri_ornekleme <- sample(1:nrow(veri), 144)
#veri türlerini listeleme
sapply(veri, class)
veri_egitim <- veri[veri_ornekleme, ]
veri_test <- veri[-veri_ornekleme, ]
dim(veri_test)
dim(veri_egitim)
#ihr_tutari veri tahmini için gereken kod
prm_birles <- function(cvp, dt){
  nms <- names(dt)
  fmla <- as.formula(paste(cvp, "~", paste(nms[!nms %in% cvp], collapse="+")))
```

```

fmla
}
duzgun_veri <- prm_birles("ihr_tutari", veri)
model_dort_iki <- neuralnet(duzgun_veri,
  data= veri_egitim,
  hidden = c(4,2),
  linear.output=T)
plot(model_dort_iki)
plotnet(model_dort_iki)
#iki katmanlı model
model_bes_uc <- neuralnet(duzgun_veri,
  data=veri_egitim,
  hidden = c(5,3),
  linear.output = T)
plot(model_bes_uc)
#iki katmanlı model
model_alti_dort <- neuralnet(duzgun_veri,
  data=veri_egitim,
  hidden = c(6,4),
  linear.output = T)
plot(model_alti_dort)
#iki katmanlı model
model_alti_bes <- neuralnet(duzgun_veri,
  data=veri_egitim,
  hidden = c(6,5),
  linear.output = T)
plot(model_alti_bes)
#iki katmanlı model
model_sekiz_uc <- neuralnet(duzgun_veri,
  data=veri_egitim,
  hidden = c(8,3),

```

```

        linear.output = T)
plot(model_sekiz_uc)
#iki katmanlı model
model_sekiz_bes <- neuralnet(duzgun_veri,
        data=veri_egitim,
        hidden = c(8,5),
        linear.output = T)
plot(model_sekiz_bes)
#üç katmanlı model
model_bes_dort_uc <- neuralnet(duzgun_veri,
        data=veri_egitim,
        hidden = c(5,4,3),
        linear.output = T)
plot(model_bes_dort_uc)
#üç katmanlı model
model_uc_altı_yedi <- neuralnet(duzgun_veri,
        data=veri_egitim,
        hidden = c(3,6,7),
        linear.output = T)
plot(model_uc_altı_yedi)
#üç katmanlı model
model_dort_bes_sekiz <- neuralnet(duzgun_veri,
        data=veri_egitim,
        hidden = c(4,5,8),
        linear.output = T)
plot(model_dort_bes_sekiz)
#tek gizli katmanlı model
model_sekiz <- neuralnet(duzgun_veri,
        data=veri_egitim,
        hidden=8,
        linear.output = T)

```

```

plot(model_sekiz)
cols <- heat.colors(5)
garson(model_sekiz) +
  scale_y_continuous('Rel. Importance', limits = c(-1, 1)) +
  scale_fill_gradientn(colours = cols) +
  scale_colour_gradientn(colours = cols)
garson(model_bes_uc)
#tek gizli katmanlı model
model_yedi <- neuralnet(duzgun_veri,
  data=veri_egitim,
  hidden=7,
  linear.output = T)
plot(model_yedi)
#model dort_iki hata
pr.nnet1 <- compute(model_dort_iki, veri_egitim[,1:6])
pr.nnet1 <- pr.nnet1$net.result*(max(veri$ihir_tutari)-min(veri$ihir_tutari))+min(veri$ihir_tutari)
test.vv <- (veri_egitim$ihir_tutari)*(max(veri$ihir_tutari)-min(veri$ihir_tutari))+min(veri$ihir_tutari)
MSEbir1 <- sum((test.vv - pr.nnet1)^2)/nrow(veri_egitim)
print(MSEbir1)
pr.nnet1 <- compute(model_dort_iki, veri_test[,1:6])
pr.nnet1 <- pr.nnet1$net.result*(max(veri$ihir_tutari)-min(veri$ihir_tutari))+min(veri$ihir_tutari)
test.vv <- (veri_test$ihir_tutari)*(max(veri$ihir_tutari)-min(veri$ihir_tutari))+min(veri$ihir_tutari)
MSEbir <- sum((test.vv - pr.nnet1)^2)/nrow(veri_test)
print(MSEbir)
#model bes_uc hata
pr.nnet2 <- compute(model_bes_uc, veri_egitim[,1:6])

```

```

pr.nnet2 <- pr.nnet2$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
test.vv <- (veri_egitim$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
MSEiki2 <- sum((test.vv - pr.nnet2)^2)/nrow(veri_egitim)
print(MSEiki2)
pr.nnet2 <- compute(model_bes_uc, veri_test[,1:6])
pr.nnet2 <- pr.nnet2$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
test.vv <- (veri_test$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
MSEiki <- sum((test.vv - pr.nnet2)^2)/nrow(veri_test)
print(MSEiki)
#model model_altı_dort hata
pr.nnet3 <- compute(model_altı_dort, veri_egitim[,1:6])
pr.nnet3 <- pr.nnet3$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
test.vv <- (veri_egitim$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
MSEuc1 <- sum((test.vv - pr.nnet3)^2)/nrow(veri_egitim)
print(MSEuc1)
pr.nnet3 <- compute(model_altı_dort, veri_test[,1:6])
pr.nnet3 <- pr.nnet3$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
test.vv <- (veri_test$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
MSEuc <- sum((test.vv - pr.nnet3)^2)/nrow(veri_test)
print(MSEuc)
#model model_altı_bes hata
pr.nnet4 <- compute(model_altı_bes, veri_egitim[,1:6])

```

```

pr.nnet4 <- pr.nnet4$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tu-
tari)
test.vv <- (veri_egitim$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tu-
tari))+min(veri$ih_r_tutari)
MSEdort1 <- sum((test.vv - pr.nnet4)^2)/nrow(veri_egitim)
print(MSEdort1)
pr.nnet4 <- compute(model_altı_bes, veri_test[,1:6])
pr.nnet4 <- pr.nnet4$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tu-
tari)
test.vv <- (veri_test$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tu-
tari)
MSEdort <- sum((test.vv - pr.nnet4)^2)/nrow(veri_test)
print(MSEdort)
#model model_sekiz_uc hata
pr.nnet5 <- compute(model_sekiz_uc, veri_egitim[,1:6])
pr.nnet5 <- pr.nnet5$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tu-
tari)
test.vv <- (veri_egitim$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tu-
tari))+min(veri$ih_r_tutari)
MSEbes1 <- sum((test.vv - pr.nnet5)^2)/nrow(veri_egitim)
print(MSEbes1)
pr.nnet5 <- compute(model_sekiz_uc, veri_test[,1:6])
pr.nnet5 <- pr.nnet5$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tu-
tari)
test.vv <- (veri_test$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tu-
tari)
MSEbes <- sum((test.vv - pr.nnet5)^2)/nrow(veri_test)
print(MSEbes)
#model model_sekiz_bes hata
pr.nnet6 <- compute(model_sekiz_bes, veri_egitim[,1:6])

```



```

pr.nnet6 <- pr.nnet6$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
test.vv <- (veri_egitim$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
MSEalti1 <- sum((test.vv - pr.nnet6)^2)/nrow(veri_egitim)
print(MSEalti1)
pr.nnet6 <- compute(model_sekiz_bes, veri_test[,1:6])
pr.nnet6 <- pr.nnet6$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
test.vv <- (veri_test$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
MSEalti <- sum((test.vv - pr.nnet6)^2)/nrow(veri_test)
print(MSEalti)
#model model_bes_dort_uc hata
pr.nnet7 <- compute(model_bes_dort_uc, veri_egitim[,1:6])
pr.nnet7 <- pr.nnet7$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
test.vv <- (veri_egitim$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
MSEyedi1 <- sum((test.vv - pr.nnet7)^2)/nrow(veri_egitim)
print(MSEyedi1)
pr.nnet7 <- compute(model_bes_dort_uc, veri_test[,1:6])
pr.nnet7 <- pr.nnet7$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
test.vv <- (veri_test$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
MSEyedi <- sum((test.vv - pr.nnet7)^2)/nrow(veri_test)
print(MSEyedi)
#model model_uc_alti_vedi hata

```

```

pr.nnet8 <- pr.nnet8$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
test.vv <- (veri_egitim$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
MSEsekiz1 <- sum((test.vv - pr.nnet8)^2)/nrow(veri_egitim)
print(MSEsekiz1)
pr.nnet8 <- compute(model_uc_altı_yedi, veri_test[,1:6])
pr.nnet8 <- pr.nnet8$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
test.vv <- (veri_test$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
MSEsekiz <- sum((test.vv - pr.nnet8)^2)/nrow(veri_test)
print(MSEsekiz)
#model model_dort_bes_sekiz hata
pr.nnet9 <- compute(model_dort_bes_sekiz, veri_egitim[,1:6])
pr.nnet9 <- pr.nnet9$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
test.vv <- (veri_egitim$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
MSEdokuz1 <- sum((test.vv - pr.nnet9)^2)/nrow(veri_egitim)
print(MSEdokuz1)
pr.nnet9 <- compute(model_dort_bes_sekiz, veri_test[,1:6])
pr.nnet9 <- pr.nnet9$net.result*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
test.vv <- (veri_test$ih_r_tutari)*(max(veri$ih_r_tutari)-min(veri$ih_r_tutari))+min(veri$ih_r_tutari)
MSEdokuz <- sum((test.vv - pr.nnet9)^2)/nrow(veri_test)
print(MSEdokuz)
.....

```

```

abline(0,1, lwd=2)
legend('bottomright', legend=c('YSA(5,3)', 'YSA(4,2)'), pch=15, col=c('red','blue'))
#YSA(5,3)-YSA(6,4)
plot(veri_test$ih_r_tutari,pr.nnet2, col='red', main='YSA(5,3) - YSA(6,4)', pch=18, cex=0.8)
points(veri_test$ih_r_tutari, pr.nnet3, col='blue', pch=16, cex=0.8)
abline(0,1, lwd=2)
legend('bottomright', legend=c('YSA(5,3)', 'YSA(6,4)'), pch=15, col=c('red','blue'))
#YSA(5,3)-YSA(6,5)
plot(veri_test$ih_r_tutari,pr.nnet2, col='red', main='YSA(5,3) - YSA(6,5)', pch=18, cex=0.8)
points(veri_test$ih_r_tutari, pr.nnet4, col='blue', pch=16, cex=0.8)
abline(0,1, lwd=2)
legend('bottomright', legend=c('YSA(5,3)', 'YSA(6,5)'), pch=15, col=c('red','blue'))
#YSA(5,3)-YSA(8,3)
plot(veri_test$ih_r_tutari,pr.nnet2, col='red', main='YSA(5,3) - YSA(8,3)', pch=18, cex=0.8)
points(veri_test$ih_r_tutari, pr.nnet5, col='blue', pch=16, cex=0.8)
abline(0,1, lwd=2)
legend('bottomright', legend=c('YSA(5,3)', 'YSA(8,3)'), pch=15, col=c('red','blue'))
#YSA(5,3)-YSA(8,5)
plot(veri_test$ih_r_tutari,pr.nnet2, col='red', main='YSA(5,3) - YSA(8,5)', pch=18, cex=0.8)
points(veri_test$ih_r_tutari, pr.nnet6, col='blue', pch=16, cex=0.8)
abline(0,1, lwd=2)
legend('bottomright', legend=c('YSA(5,3)', 'YSA(8,5)'), pch=15, col=c('red','blue'))
#YSA(5,3)-YSA(5,4,3)
plot(veri_test$ih_r_tutari,pr.nnet2, col='red', main='YSA(5,3) - YSA(5,4,3)', pch=18, cex=0.8)
points(veri_test$ih_r_tutari, pr.nnet7, col='blue', pch=16, cex=0.8)
abline(0,1, lwd=2)
legend('bottomright', legend=c('YSA(5,3)', 'YSA(5,4,3)'), pch=15, col=c('red','blue'))
#YSA(5,3)-YSA(3,6,7)

```

```

legend('bottomright', legend=c('YSA(5,3)', 'YSA(3,6,7)'), pch=15, col=c('red','blue'))
#YSA(5,3)-YSA(4,5,8)
plot(veri_test$ihr_tutari,pr.nnet2, col='red', main='YSA(5,3) - YSA(4,5,8)', pch=18, cex=0.8)
points(veri_test$ihr_tutari, pr.nnet9, col='blue', pch=16, cex=0.8)
abline(0,1, lwd=2)
legend('bottomright', legend=c('YSA(5,3)', 'YSA(4,5,8)'), pch=15, col=c('red','blue'))
#farklı iterasyon sonuçları
model_dnm <- train(ihr_tutari~ ., data=veri_egitim, method="neuralnet", prePro-
cess=c("center","scale"), tuneLength =10)
model_dnm
plot(model_dnm)
model_dnm_2 <- train(ihr_tutari~ ., data=veri_egitim, method="neuralnet", tuneG-
rid=expand.grid(layer1=c(5), layer2=3, layer3=0))
model_dnm_2
plot(model_dnm_2)
#regresyon
reg.model <- lm(formula = ihr_tutar ~ uret_endeks + s.nai_kap + usd_al +
tekn_endeks + ihr_endeks , data = zaman_seri)
summary(reg.model)
#ysa ve regresyon
lm.pred <- predict(reg.model, veri_test)
print(lm.pred)
MSE.lm <- sum((lm.pred - veri_test$ihr_tutari)^2)/nrow(veri_test)
MSE.lm
par(mfrow=c(1,2))
plot(veri_test$ihr_tutari, pr.nnet2, col='red', main='Gerçek-Tahmin(Reg)', pch=18, cex=0.7,
abline(0,1,lwd=2))
legend('bottomright', legend='Reg', pch=18, col='red', bty='n')
plot(veri_test$ihr_tutari, lm.pred, col='green', main='Gerçek-Tahmin(YSA)', pch=18, cex=0.7,
abline(0,1,lwd=2))

```

```
accuracy(lm.pred, veri_test)
```

```
#aynı grafikte
```

```
plot(veri_test$ihr_tutari, pr.nnet2, col='red', main='(YSA)-(Regresyon)', pch=18, cex=0.7)
```

```
points(veri_test$ihr_tutari, lm.pred,col='green', pch=18, cex=0.7)
```

```
abline(0,1,lwd=2)
```

```
legend('bottomright', legend=c('Reg', 'NN'), pch=18, col=c('red','green'))
```

```
#zaman serisi
```

```
install.packages("forecast")
```

```
library("forecast")
```

```
library(tidyverse)
```

```
library(readr)
```

```
library(stringr)
```

```
install.packages("fpp2")
```

```
library(fpp2)
```

```
library(ggplot2)
```

```
library(scales)
```

```
library(tseries)
```

```
library(data.table)
```

```
library(lubridate)
```

```
library(forecast)
```

```
zaman_seri <- read.csv(file='C:/Users/sengul.can/Desktop/YSA-Döküman/verizs.csv',
```

```
head=TRUE, sep=";", stringsAsFactors = FALSE)
```

```
ihr_toplam <- ts(data=zaman_seri$ihr_tutari,
```

```
frequency=12,
```

```
start=c(2005,01),
```

```
end=c(2019,12))
```

```

        frequency = 12,
        start=c(2005, 01),
        end=c(2016, 12))
print(egitim_veri)
test_veri <- ts(ihr_toplam[145:length(ihr_toplam)],
               frequency = 12,
               start=c(2017,01),
               end=c(2019,12))
#otokorelasyon
ggAcf(ihr_toplam, lag.max = 60) + ggtitle("Otokorelasyon Fonksiyonu Grafiği")
#mevsimsellik ve trend inceleme
decomposedRes <- decompose(x=ihr_toplam)
stl_ts <- stl(ihr_toplam, s.window = "periodic")
plot(decomposedRes, lwd=2)
trend <- stl(ihr_toplam, s.window = "periodic")$time.series[,2]
detrend <- ihr_toplam - trend
checkresiduals(detrend)
adf.test(detrend)

egitim_veri <- ts(detrend[1:144],
                 frequency=12,
                 start=c(2005,01),
                 end=c(2016,12))
test_veri <- ts(detrend[145:length(detrend)],
               frequency=12,
               start = c(2017,01),
               end=c(2019,12))
plot(detrend, type="o", col=1, lwd=2, axes = F, xlab="Trend durağan veri", ylab="")

```

```

abline(reg=lm(detrend ~ time(detrend)), col="blue")
plot(decompose(detrend))
#library(urroot)
#urroot::ch.test(ts(detrend, frequency = 12, start=c(2005,01), end=c(2019,12)),
type="dummy")
Box.test(detrend, type = 'Ljung')
detrend_lineer_model <- tslm(detrend ~ trend + season)
summary(detrend_lineer_model)
lmtest::dwtest(detrend_lineer_model)
meanf_tahmin <- meanf(egitim_veri, h=36)$mean
rwf_tahmin <- rwf(egitim_veri, h=36)$mean # Random Walk Forecast
rwf_tahmin_2 <- rwf(egitim_veri, drift = TRUE, h=36)$mean # Drift Model (Ürettiği Random
Walk değeri ile ver
snaive_tahmin <- snaive(egitim_veri, h=36)$mean
accuracy(snaive_tahmin, test_veri)
plot(detrend, main="Toplam İhracat", ylab="", xlab="Tarih")
lines(meanf_tahmin, col=13, lwd=3)
#lines(rwf_tahmin, col=1, lwd=1)
#lines(rwf_tahmin_2, col=1, lwd=1)
lines(snaive_tahmin, col=4, lwd=3)
legend("topleft", xjust = 0.2, lty=1, col=c(13,2,12, 4),
legend=c("Mean method", "random walk method", "random walk Drift method", "Seasonal
naive method"), bty="n", lw
#ARIMA
auto.arima(egitim_veri, stepwise = T, trace=T)

print(arima_model)
summary(arima_model)
#NN <- nnetar(as.numeric(unlist(veri_egitim)), size=3, p=2, P=2, lambda="auto", re-
peats=10)
NN <- nnetar(as.numeric(veri_egitim), size=3, p=2, P=2, lambda="auto", repeats = 10)
plot(forecast(NN, h=16), ylim=c(min(veri$ihir_tutari), max(veri$ihir_tutari)))
lines(veri_test, type="o", color="red", lwd=2)
legend("topleft", c("Tahmin - YSA", "test verisi"), lwd=c(3,3), col=c("blue", "red"))
accuracy(forecast(NN, 16), test_veri)

```