



T.C.
KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ

YAPAY ZEKA YÖNTEMLERİ İLE TALEP TAHMİNİ VE
DEĞİRMEN MAKİNELERİ İMALAT SEKTÖRÜNDE
UYGULANMASI

AZİZE BERNA CAN
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

DANIŞMAN
Doç. Dr. Adnan AKTEPE

KIRIKKALE-2023



T.C.
KIRIKKALE ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ

YAPAY ZEKA YÖNTEMLERİ İLE TALEP TAHMİNİ VE
DEĞİRMEN MAKİNELERİ İMALAT SEKTÖRÜNDE
UYGULANMASI

AZİZE BERNA CAN
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI

YÜKSEK LİSANS TEZİ

DANIŞMAN
Doç. Dr. Adnan AKTEPE

KIRIKKALE-2023

KABUL ve ONAY

Azize Berna CAN tarafından hazırlanan “YAPAY ZEKA YÖNTEMLERİ İLE TALEP TAHMİNİ VE DEĞİRMEN MAKİNELERİ İMALAT SEKTÖRÜNDE UYGULANMASI” adlı tez çalışması aşağıdaki jüri tarafından OY BİRLİĞİ ile Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalında YÜKSEK LİSANS TEZİ olarak kabul edilmiştir.

Danışman: Doç. Dr. Adnan AKTEPE

İmza.....

Endüstri Müh. A.B.D., Kırıkkale Üni.

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Başkan: Prof. Dr. Süleyman ERSÖZ

İmza.....

Endüstri Müh. A.B.D., Kırıkkale Üni.

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum

Üye: Doç. Dr. Hakan ÇERÇİOĞLU

İmza.....

Endüstri Müh. A.B.D., Gazi Üni.

Bu tezin, kapsam ve kalite olarak Yüksek Lisans Tezi olduğunu onaylıyorum/onaylamıyorum .

Tez Savunma Tarihi: 10/02/2023

Jüri tarafından kabul edilen bu tezin Yüksek Lisans Tezi olması için gerekli şartları yerine getirdiğini onaylıyorum.

Prof. Dr. Recep ÇALIN

Fen Bilimleri Enstitüsü Müdürü

ETİK BEYANI

Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü Tez Yazım Kurallarına uygun olarak hazırladığım bu tez çalışmada;

- Tez içinde sunduğum verileri, bilgileri ve dokümanları akademik ve etik kurallar çerçevesinde elde ettiğimi,
- Tüm bilgi, belge, değerlendirme ve sonuçları bilimsel etik ve ahlak kurallarına uygun olarak sunduğumu,
- Tez çalışmada yararlandığım eserlerin tümüne uygun atıfta bulunarak kaynak gösterdiğimi,
- Kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- Bu tezde sunduğum çalışmanın özgün olduğunu,

bildirir, aksi bir durumda aleyhime doğabilecek tüm hak kayıplarını kabullendiğimi beyan ederim.

İMZA

AZİZE BERNA CAN

ÖZET

YAPAY ZEKA YÖNTEMLERİ İLE TALEP TAHMİNİ VE MAKİNE İMALAT SEKTÖRÜNDE UYGULANMASI

CAN, Azize Berna

Kırıkkale Üniversitesi

Fen Bilimleri Enstitüsü

Endüstri Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi

Günümüz şartlarında artan rekabet ortamında şirketlerin mevcut durumlarını koruyabilmeleri ve geliştirebilmeleri için talep tahmini büyük önem taşımaktadır. Talep tahmini, bir ürün ya da hizmetin belirli bir gelecek dönem için satışlarının en az hata ile tahmin edilmesidir. Böylece işletmelerin gelecek dönemlerde karşılaşılabilecekleri durumlar öngörülebilir ve çeşitli yöntemler kullanılarak önceden önlemler alınabilir. Talep tahmin yöntemleri, kalitatif yöntemler ve kantitatif yöntemler olarak iki gruba ayrılmaktadır. Kalitatif tahmin metodu, istatistiksel yöntem kullanılmadan insanların sezgisel yaklaşımlarına dayalı yapılan bir talep tahmin yöntemidir. Kantitatif metot ise tam tersine çeşitli istatistiksel yöntemler kullanılarak yapılan yöntemlerdir.

Bu çalışmada talep tahmin kavramından bahsedilmiş ve talep tahmin yönetiminde kullanılan tahmin yöntemleri incelenmiştir. Ardından literatürde yer alan yapay zekâ tabanlı talep tahmin yöntemlerinden bahsedilmiştir. Çalışmanın uygulama bölümünden yapay zekâ tabanlı yöntemlerden olan Destek vektör makineleri (DVM) ve Yapay sinir ağları (YSA) ve yöntemleri kullanılarak değirmen makineleri imalatı yapan bir işletme için talep tahmin çalışması yapılmıştır. Elde edilen sonuçlara göre DVM'nin YSA'ya göre daha başarılı tahminler yaptığı bu çalışma ile sunulmuştur.

Anahtar Kelimeler: Değirmen Makineleri İmalatı, Destek Vektör Makineleri (DVM), Yapay Sinir Ağları (YSA).

ABSTRACT

In today's increasingly competitive environment, demand forecasting is of great importance for companies to maintain and improve their current situation. Demand forecasting is the estimation of sales of a product or service for a certain future period with the least error. Thus, the situations that businesses may encounter in the future periods can be foreseen and measures can be taken in advance using various methods. Demand forecasting methods are divided into two groups as qualitative and quantitative. The qualitative forecasting method is a demand forecasting method based on people's intuitive approaches without using the statistical method. The quantitative method, on the contrary, is the methods performed using various statistical methods.

In this study, the concept of demand forecasting was mentioned and the forecasting methods used in demand forecasting management were examined. Then, artificial intelligence-based demand forecasting methods included in the literature were mentioned. From the application section of the study, a demand forecasting study was conducted for an enterprise manufacturing milling machines using artificial neural networks (ANN) and Support vector machines (SVM) methods, which are one of the artificial intelligence techniques. According to the results obtained, it is presented with this study that SVM makes more successful estimates compared to ANN.

Keywords: Mill Machinery Manufacturing, Artificial Neural Networks (ANN), Support Vector Machines (SVM).

TEŐEKKÜR

Yüksek lisans çalışmam boyunca destek olan değerli danışmanım Doç. Dr. Adnan AKTEPE' ye, yüksek lisans eğitimimde yardımcı ve yol gösterici olan Prof. Dr. Süleyman ERSÖZ'e ve her zaman desteğini esirgemeyen aileme teşekkürlerimi sunarım.



3.3.2.2.1. Regresyon Analizi.....	16
3.3.2.2.2. Korelasyon Analizi	17
3.3.2.2.3. Box Jenkins Yöntemleri.....	18
3.3.2.2.4. Yapay Zekâ Yöntemleri.....	20
3.4. Talep Tahmin Yöntemlerinin Doğruluğunun Ölçülmesi.....	22
4. YAPAY ZEKÂ İLE TALEP TAHMİN YÖNTEMLERİ	24
4.1. Yapay Sinir Ağları (YSA)	24
4.1.1. Yapay Sinir Ağları Tanımı	24
4.1.2. Yapay Sinir Ağlarının Genel Özellikleri.....	24
4.1.3. Yapay Sinir Ağlarının Uygulama Alanları.....	25
4.1.4. Yapay Sinir Ağının Yapısı ve Temel Elemanları.....	26
4.1.5. Yapay Sinir Ağlarının Sınıflandırılması.....	31
4.1.6. Yapay Sinir Ağlarında Öğrenme Kuralları.....	34
4.1.7. Yapay Sinir Ağlarının Avantajları ve Dezavantajları	35
4.2. Destek Vektör Makineleri (DVM).....	36
4.2.1. Destek Vektör Makineleri Sınıflandırması.....	37
4.2.1.1. Maksimum Marj Destek Vektör Makineleri (Doğrusal Ayrılabilir Durum).....	37
4.2.1.2. Yumuşak Marj Destek Vektör Makineleri	39
4.2.2. Destek Vektör Regresyon.....	40
4.2.3. Doğrusal Olmayan Destek Vektör Regresyon	42
5. YAPAY SİNİR AĞLARI VE DESTEK VEKTÖR UYGULAMASI.....	44
5.1. Firma ve Ürün Bilgisi	44
5.2. Problemin Tanımlanması ve Veri Setinin Oluşturulması.....	44
5.3. Yapay Sinir Ağı Mimarisinin Oluşturulması ve Ağın Eğitilmesi	50
5.4. Yapay Sinir Ağları Tahmin Uygulaması	51
5.5. Destek Vektör Makineleri Tahmin Uygulaması.....	56
6. SONUÇ VE DEĞERLENDİRME	58
KAYNAKLAR	59
ÖZGEÇMİŞ.....	65

ÇİZELGELER LİSTESİ

<u>ÇİZELGE</u>	<u>Sayfa</u>
Çizelge 3.1. Korelasyon katsayısı değerleri ve yorumlanması (Tekin, 2009)	18
Çizelge 4.1. Biyolojik sinir hücresi ve yapay sinir hücresi arasındaki ilişki (Efe ve Kaynak, 2000)	28
Çizelge 4.2. Toplama fonksiyon çeşitleri (Kölmek, 2012)	29
Çizelge 4.3. Aktivasyon fonksiyon çeşitleri (Gürsoy, 2012)	30
Çizelge 4.4. Bazı Kernel Fonksiyonları (Kavzoglu ve Çölkesen, 2009)	43
Çizelge 5.1. Aylık satış verileri	45
Çizelge 5.2. Buğday adetleri	46
Çizelge 5.3. Aylık buğday üretim adetleri	47
Çizelge 5.4. Dünya nüfusu verileri	48
Çizelge 5.5. Aylık Dünya Nüfusu Verileri	49
Çizelge 5.6. Aylık dolar kuru	50
Çizelge 5.7. YSA mimarisi için deneme yanılma sonuçları	50
Çizelge 5.8. YSA sonuçları	54
Çizelge 5.9. DVM hata sonuçları	57
Çizelge 6.1. Tahmin başarılarının karşılaştırılması	58

ŞEKİLLER LİSTESİ

<u>ŞEKİL</u>	<u>Sayfa</u>
Şekil 3.1. Talep tahmin yöntemleri (Türk ve Kaini, 2019).....	11
Şekil 3.2. Çeşitli talep düzeylerinin zamana göre değişimi (Üreten, 2005)	13
Şekil 3.3. Regresyon doğrusu (Karahan, 2011)	17
Şekil 3.4. Korelasyon katsayısı eğrisi (Karahan, 2011).....	18
Şekil 3.5. Box-Jenkins metodolojisi (Hyndman, 2001).....	19
Şekil 4.1. Biyolojik sinir ağı hücresi (Maltarollo vd., 2013)	26
Şekil 4.2. Yapay sinir hücresi yapısı (Uslu, 2016)	27
Şekil 4.3. Sigmoid fonksiyonunun gösterimi (Yücesoy , 2011).....	30
Şekil 4.4. Yapay sinir ağı mimarisi (Kartalopoulos, 1996)	31
Şekil 4.5. İleri beslemeli yapay sinir ağı isleyişi (Güven, 2020)	32
Şekil 4.6. Geri beslemeli yapay sinir ağı isleyişi (Güven, 2020).....	33
Şekil 4.7. Geri Beslemeli Geri Yayılmalı Sinir Ağı Modeli Mimarisi (Rajpal vd., 2006)	33
Şekil 4.8. Maksimum marj hiperdüzlem (Kavzoglu ve Çölkesen, 2009).....	38
Şekil 4.9. Doğrusal ayrılmayan değişkenler (Smola ve Schölkopf, 2004)	39
Şekil 4.10. e-duyarsız kayıp fonksiyon (Moura vd., 2011).....	41
Şekil 5.1. Dünyada üretilen buğday miktarları (Statista, n.d).....	46
Şekil 5.2. Dünya nüfus verileri (Statista, n.d).....	48
Şekil 5.3. Verilerin Matlab'a girilmesi	51
Şekil 5.4. Verilerin normalizasyonu	51
Şekil 5.5. Ağın oluşturulması.....	52
Şekil 5.6. Ağın eğitilmesi.....	52
Şekil 5.7. Ağın performans testi	53
Şekil 5.8. Regresyon grafiği.....	55
Şekil 5.9. Performans grafiği	55
Şekil 5.10. DVR model yapısı	56

KISALTMALAR DİZİNİ

YZ	Yapay Zeka
GO	Genetik Algoritmalar
YSA	Yapay Sinir Ağları
DVM	Destek Vektör Makineleri
MAPE	Ortalama Mutlak Hata Yüzdesi
MAE	Ortalama Mutlak Hata
MSE	Ortalama Hata Karesi
ME	Ortalama Hata
AR	Otoregresif
MA	Hareketli Ortalamalar
ARIMA	Otoregresif Bütünleşik Hareketli Ortalamalar modeli
AR-MA	Otoregresif Hareketli Ortalamalar

1. GİRİŞ

Günümüz şartlarında dünya nüfusunun giderek artması tarım ve gıda sektörüne olan talebi etkilemiştir. Tarım sektörü tarıma dayalı üretimin dışında diğer sektörlerle de katkı sağlaması açısından oldukça önemlidir (Halike ve Direk, 2022). Tarım sektörü ülkelerin gelişmişlik düzeyinden bağımsız olarak bütün ülkeler için ekonomik olarak önemli bir yere sahiptir (Bulu, Eraslan ve Balca, 2007). Ülkemizde tarım, hem tarıma dayalı gıda sanayilerine hammadde üretme açısından, hem de tarım ürünlerinin pazarlama olanaklarının genişletilmesi ve katma değerinin yükselmesi gibi nedenlerden dolayı önemli bir yere sahiptir. TÜİK'ten elde edilen bitkisel üretim tahmin verilerine göre ülkemizde tahıl ürünleri üretim adetlerinin 2022 yılında önceki yıla göre %20,7 oranında artış göstererek 38,5 milyon ton olacağı varsayılmaktadır. Aynı zamanda bir önceki yıl ile kıyaslandığında arpa üretim adetleri yaklaşık %47 oranında artış göstererek 8,5 milyon ton, buğday üretim adetlerinin yaklaşık %11 oranında artış göstererek 19,8 milyon ton, yulaf üretiminin yaklaşık %32 oranında artış göstererek 365 bin ton olarak tahmin edilmiştir (TUIK,2022). Buğday, arpa, mısır, çavdar, yulaf gibi çeşitli tahılların belirli işlemlerden geçip temel besin kaynaklarına dönüşmesinde değirmen endüstrisine ihtiyaç vardır. Değirmen makineleri geniş kullanım alanlarına sahiptir. Bunlardan bazıları; un, yem, irmik fabrikaları, tahıl işleme tesisleri, yağ fabrikaları gibi gıda sektöründe birçok alanda kullanılmaktadır.

Gıda sektörüne olan talebin artması beraberinde değirmen makineleri ihtiyacını da arttırmıştır. Bu da sektörde değirmen makineleri imalatında faaliyet gösteren işletmelerin sayısının artmasıyla hem iç pazarda hem de dış pazarda rekabete yol açmaktadır. Gelişen teknoloji, sanayileşmenin artması, ekonomik dalgalanmalar ile beraber işletmeler mevcut durumlarını koruyabilmek ve gelişebilmek için gelecek ile ilgili tahminlerini iyi yapmaları gerekmektedir. Bu nedenle firmaların stratejik kararlar alırken kısa ve uzun dönemlik planlarının başında talep tahmini gelmektedir.

Gerçeğe yakın yapılan talep tahmini ile güçlü bir planlama etkin bir tedarik zinciri yönetimi ve sonunda artan kâr marjı ve artan müşteri memnuniyetine ulaşılmaktadır.

Bu çalışmada, değirmen makineleri üreticisi bir firmanın temizleme ve tavlama makineleri ürün grubu için yapay zekâ tekniklerinden olan yapay sinir ağları ve destek vektör makineleri yöntemlerini kullanarak talep tahmini çalışması yapılmıştır.

İkinci bölümde, destek vektör makineleri, talep tahmini ve yapay zekâ yöntemleri ile ilgili ele alınan çalışmalar incelenmiş ve özet halinde sunulmuştur. Üçüncü bölümde, talep tahmin kavramı, talep tahmin aşamaları ve talep tahmin yöntemlerinden detaylıca bahsedilmiştir. Dördüncü bölümde yapay zekâ tabanlı yöntemlerden olan destek vektör makinelerinden ve yapay sinir ağlarından detaylıca bahsedilmiştir. Beşinci bölümde destek vektör makineleri ve yapay sinir ağları yöntemleri ile talep tahmin uygulaması yapılmış ve sonuçları karşılaştırılmıştır. En son bölümde elde edilen sonuçlar paylaşılmıştır.

2. LİTERATÜR TARAMASI

Talep tahmini, gelecek ile ilgili planlamalar yapılırken, stratejik kararlar alınırken hedefe ulaşmada kullanılan önemli araçlardan birisidir (Yazıcıoğlu, 2010). Tüketici taleplerinin günden güne değişmesi talep tahmin yöntemlerinde de çeşitliliğe neden olmuştur. Bu nedenle günümüzde gelecek ile ilgili tahmin yürütebilmek şirketler açısından büyük bir önem kazanmıştır.

Bu tez kapsamında geçmişten günümüze literatürde yayınlanan talep tahmin çalışmaları incelenmiştir. İncelenen talep tahmini çalışmalarından bazıları özetlenerek aşağıda sunulmuştur:

Acı ve Doğansoy (2022) yapmış oldukları çalışmalarında bir süpermarkete ait 2019 ve 2020 yılları arasındaki verileri ile satışı etkileyen faktörler; TÜFE, işsizlik oranı ve tatil günleri alınarak belirli bir grup ürün için talep tahmin çalışması yapılmıştır. En iyi modele ulaşabilmek için farklı yapay zekâ algoritmasına ait yöntemler kullanılmıştır. Kullanılan yirmi dört farklı yöntemden elde edilen sonuçlar satış kampanyalarında, pazarlama stratejilerinde ve ürün tedarikinin doğru miktarlarda yapılmasında kullanılarak e-perakende satışlarının başarısını arttırabileceği sonucuna varmışlardır.

Akman, Yılmaz ve Sönmez (2018) yapmış oldukları çalışmalarında enerji sektörü için kullanılan yük tahminleme yönteminin avantajları ve dezavantajlarını araştırıp uygun modellerin geliştirilmesine olanak sağlamışlardır. Çalışmada yük tahmini için Destek Vektör Makineleri, Regresyon Analizi, Zaman Serileri Analizi, Hibrit, Yapay Sinir Ağları ve Diğer Yaklaşımlar gibi metotlar denemiş ve sonuçlar paylaşılmıştır.

Aydın (2012) ele aldığı çalışmada özel deniz taşımacılığı yapan bir işletmenin 2007-2011 yıllarına ait verilerini kullanarak tahmin çalışması gerçekleştirmiştir. Çalışmada Yapay Sinir Ağları tekniklerinden olan Çok Katmanlı Algılayıcı (ÇKA) ve Elman-Jordan modellerini kullanmıştır. ÇKA modelinin Elman-Jordan modeline göre daha düşük tahmin hatası ürettiği sonucuna varmıştır.

Aylak, Oral, Yazıcı (2021) çalışmalarında, lojistik sektöründe kullanılan makine öğrenmesi yapay zekâ uygulama alanları detaylı bir şekilde incelenmiştir. Lojistik sektöründe bu yöntemler kullanılarak farklı konularda uygulamalar yapılmış ve sonuçları paylaşılmıştır. Elde edilen sonuçlara göre tedarik zinciri yönetimi ve lojistik alanında yapay zekanın iyi sonuçlar verdiği ve lojistik süreçleri kolaylaştırdığı sonucuna varılmıştır.

Ballı (2014) yapmış olduğu çalışmada gıda sektöründe yapay sinir ağı yöntemi kullanılarak şarküteri grubu ürünlerinin 2010-2013 yıllarına ait verilerini kullanarak 2014 yılı için talep tahmini uygulaması yapmıştır. Modelden elde edilen sonuçlara göre %85 oranında başarılı olduğu sonucuna varılmıştır.

Bayar (2019) Türkiye’de elektrik enerjisi talep tahmin çalışması gerçekleştirmiştir. Yapmış olduğu uygulamada yapay sinir ağları ve diferansiyel polinom sinir ağları tekniklerini kullanmıştır. Girdi verileri olarak 1965-2016 yıllarına ait ithalat, kurulu güç, nüfus, ihracat ve gayri safi yurtiçi hasıla değişkenleri alınmıştır. İki yöntem karşılaştırıldığında diferansiyel polinom sinir ağı yönteminin daha iyi sonuç verdiği gözlenmiştir.

Bunjaku (2014) çalışmasında veri tabanında bulunan gri seviyeli yüz görüntülerini tanıma çalışması yapmıştır. Çalışmasında PNN (Olasılıksal Sinir Ağı) ve DVM (Destek Vektör Makineleri) yöntemlerini kullanmıştır. Elde edilen sonuçların işlem süresi ve performansları kıyaslanmıştır ve PNN yönteminin DVM yöntemine göre daha başarılı sonuçlar gösterildiği sunulmuştur.

Çoban ve Demir (2021) yapmış oldukları çalışmada bir gıda işletmesinde 52 ayın verileri alınarak Yapay Sinir Ağları (YSA) ve Destek Vektör Regresyonu (DVR) yöntemleri ile talep tahmini yapmışlardır. Çalışmada MATLAB programı kullanılmıştır. Elde edilen sonuçlara göre çalışma yapılan ürünler için YSA ve DVR kıyaslandığında YSA’nın daha başarılı tahminler yaptığı sonucuna varmışlardır.

Durgun (2018) çalışmasında Türkiye’nin 1980-2017 yıllarına ait verilerini kullanılarak 2018 – 2023 yılları için elektrik enerjisi talebinin yapay zekâ teknikleri ve regresyon analizi ile tahmin çalışması yapmıştır. Çalışmada WEKA ve MATLAB programları kullanılmıştır. Her veri için MAPE değerleri elde edilmiştir ve sonuçlar karşılaştırılmıştır.

Efendigil ve Eminler (2017) ele aldıkları çalışmalarında havacılık sektöründe yolcu talep tahmininin yapay zekâ teknikleri ve regresyon tekniği ile karşılaştırması yapılmıştır. Çalışmalarında havacılık sektöründe müşteri talep tahmini çalışmasında en iyi sonuçları “yapay sinir ağları” yönteminin verdiği sonucuna ulaşılmıştır.

Ervural, Uçal, Sarı ve Koçyiğit (2018) ele aldıkları çalışmalarında bir meyve suyu işletmesinin 36 aylık satış verilerini kullanarak talep tahmin çalışması yapmışlardır. Çalışmalarında bulanık mantık yaklaşımını ele almışlardır. Elde edilen sonuçlar zaman serileri yaklaşımıyla da karşılaştırılmış ve yöntemlerin başarıları sunulmuştur. Elde edilen sonuçlarla karşılaştırıldığında bulanık tabanlı tahmin modelinin başarılı olduğu sonucuna varılmıştır.

Güven (2020) ele aldığı çalışmasında hazır giyim sektöründe yapay zekâ yöntemleri kullanarak satış talep tahmini yapmıştır. Çalışmada destek vektör makineleri (DVM), yapay sinir ağları (YSA), rastgele ormanlar (RO) modelleri kullanılmıştır. Çalışmada bir hazır giyim firmasına ait 49. hafta ile 52. haftaları arasında yaptığı satışlar veri seti olarak alınmıştır. Elde edilen sonuçlara göre YSA, DVM ve RO tekniklerine göre kıyaslamalar yapılmış ve elde edilen sonuçlar çalışmada paylaşılmıştır.

Han, Sönmez, Avcı ve Aladağ (2021) çalışmalarında, Türkiye’de 2019 ve 2020 yıllarına ait sıfır otomobil satış adetlerinin tahmin çalışmasını gerçekleştirmişlerdir. Uygulamada Yapay Sinir Ağları (YSA) ve Holt Winters yöntemlerini kullanmışlardır. Çalışmada, bağımlı değişken “otomobil satış adetleri”; bağımsız değişkenler “gayrisafi yurt içi hasıla, tüketici güven endeksi, reel kesim güven endeksi, döviz kuru” olarak belirlenmiştir. Çalışmanın sonucundan elde edilen verilere göre, YSA’nın performansının Holt Winters’ yöntemine göre daha iyi sonuç verdiği tespit edilmiştir.

Karaatlı, Ömürbek, Helvacıoğlu ve Tokgöz (2012) Türkiye’de sıfır otomobil satış adetlerinin yapay sinir ağları yöntemiyle tahmin çalışması yapmışlardır. Çalışmalarında 2007 ve 2011 yıllarına ait aylık verileri almışlardır. Çalışmada gayri safi yurtiçi hasıla, reel kesim güven endeksi, tüketim harcamaları, yatırım harcamaları, zaman, tüketici güven endeksi ve dolar kuru bağımsız değişkenler olarak belirlenmiştir. Satılan toplam otomobil adetlerini bağımlı değişken olarak almışlardır. Elde edilen sonuçlara göre hata değerini %16,82 bularak yapılan çalışmanın ‘doğru tahminler’ sınıfında olduğu sonucuna varmışlardır.

Olgun (2009) ele aldığı çalışmasında mevcut verileri kullanılarak gelecek aylar için Türkiye otomobil satış adetlerini tahmin etmiştir. Kullanılan yöntem yapay sinir ağları yöntemidir. Çalışmasında WEKA programını kullanmıştır. Elde ettiği sonuçlara göre, Türkiye’de otomobil satış adetlerinin 2009 yılında bir önceki yıla göre artış göstermesi beklendiği sonucuna varılmıştır.

Öncel (2013) ele aldığı çalışmasında Makine Kimya Endüstrisi Kurumu Mühimmat Fabrikasının tasarlanmış olduğu sevk çemberi kaynak prosesini Yapay Sinir Ağları tekniğini kullanarak prosesin kalite düzeyini arttırmayı amaçlamışlardır. Modelde SPSS ve MATLAB programlarını kullanmışlardır. YSA sınıflandırma modellerinden olan kademeli, girdi-çıkıtı etkileşimli, ileri beslemeli ve olmak üzere 3 çeşit model oluşturulmuştur. Kademeli model ve girdi-çıkıtı etkileşimli model %100, ileri beslemeli model %95 oranında çıkıtı sonuçlarını doğru tahmin etmişlerdir.

Sakız ve Ünkaya (2018) yapmış oldukları çalışmalarında, havacılık endüstrisini etkileyen önemli 4 farklı olayın Türk Hava Yolları üzerindeki iflas riskini, havayolları için özel olarak geliştirilen bir model olan Airscore modelini kullanarak tahmin etmişlerdir. Ayrıca Airscore modellemesi ve yapay sinir ağları yöntemi kullanılarak ileriki dönemler için tahminler yapılmış ve elde edilen sonuçlara göre 2017, 2018 ve 2019 yılları için işletmenin sağlıklı alanda olacağı sonucuna varılmıştır.

Sarı (2016) ele aldığı çalışmasında yapay zekâ tekniklerinden yapay sinir ağları yöntemini kullanarak motor yataklarının satış talep tahminlerini yapmıştır. Aynı zamanda Regresyon Analizi, üstel düzeltme yöntemi, hareketli ortalama yöntemi ile de tahminler yapılmıştır. YSA ile yapılan tahminler sonucunda MAPE değeri 0.23 ve tahmin başarısı 0.77 olarak elde edilmiştir. YSA ve diğer yöntemler karşılaştırıldığında yapay sinir ağlarının gerçeğe daha yakın tahminler elde ettiği sonucuna varılmıştır.

Türk ve Kiani (2019) ele aldıkları çalışmalarında Türkiye’deki beyaz eşya satışlarını regresyon analizi ve yapay sinir ağı yöntemi kullanarak tahmin etmişlerdir. Talebi etkileyen değişkenler olarak 2015 ve 2017 yıllarına ait gayri safi yurt içi hasıla, tüketici güven endeksi, sanayi üretim endeksi, tüketim harcamaları, reel kesim güven endeksi, hanenin maddi durum beklentisi, ekonomik güven endeksi ve evlenme istatistikleri değişken olarak belirlemişlerdir. Sonuçlar incelendiğinde yapay sinir ağlarından elde edilen sonuçların regresyon analizlerinden elde edilen sonuçlara göre daha başarılı sonuç ürettiğini gözlemlemişlerdir.

Yanık (2019) yapmış olduđu çalışmada iş makineleri sektöründe imalat yapan bir firmada Yapay Sinir Ağları tekniđi ve Çok Deđişkenli Regresyon Analizi ile talep tahmin çalışması yapmıştır. Modelin girdileri olarak dolar kuru, iş makinesi adetleri ve aylık etki oranı belirlenmiştir. 9 yıllık satış verileri ile bir sonraki yılın satış tahminleri yapılmıştır. Yapılan analizler sonucunda iki yöntem karşılaştırılmış ve YSA'nın daha iyi sonuç verdiği gözlemlenmiştir.

Yazıcıođlu (2010) yapmış olduđu çalışmada Türkiye'de binek otomobil üretim adetlerinin toplamını kullanarak regresyon analizi ve yapay sinir ağları yöntemleri ile geleceđe yönelik tahminler yapmıştır. Bu çalışmada yapay sinir ağlarının binek otomobil talep tahmininde regresyon analizine göre daha iyi sonuçlar verdiği sunulmuştur.

3. TALEP TAHMİNİ

3.1. Talep Tahmin Kavramı

Tanım olarak belirli bir zamanda, belirli bir piyasada, belirli bir fiyattan, satın alınmak istenen mal veya hizmet miktarına talep denir (Aydın, 2012). Tahmin ise, bir değişkenle ilgili mevcut olan verileri kullanarak gelecek ile ilgili yaklaşık varsayımlarda bulunmaktır. Geleceği iyi tahmin etmek ileriye dönük gerekli planlamaların yapılmasına ve stratejik kararların alınmasına temel oluşturmaktadır. İyi yapılan tahminler gelecek ile ilgili belirsizliği azaltır ve belirsizliğin azalması tüm sektörler için gelecek ile ilgili gerçeğe yakın kararlar alınmasını kolaylaştırmaktadır. Bu belirsizliklerden bir tanesi de üretilen ürün ya da hizmete olan taleptir.

Talep tahmini, bir ürün ya da hizmetin belirli bir gelecek dönem için satışlarının gerçeğe yakın yaklaşık öngörüler ve en az hata ile tahmin edilmesidir. Talep tahmini, şirketlerin stratejik kararlar almasında, kısa dönem ve uzun dönemli hedeflerine ulaşırken kullandıkları temel araçlardan birisidir (Adıyaman, 2007).

Günümüz piyasasında artan rekabet koşullarında firmalar ayakta kalabilmek için karşılaştıkları problemlerle ilgili etkin kararlar almak zorunda kalırlar. Gelecekle ilgili verilecek olan kararlar belirsizlik içerdiğinden dolayı bu kararların alınmasında çeşitli yöntemlere başvurulur (Özdemir ve Özdemir, 2006). Talep tahmini gelecek ile ilgili karar vermenin yanı sıra başta yönetsel kararlar olmak üzere satın alma, üretim planlama, iş gücü planlama, finans gibi birçok alanda da kullanılmaktadır. Özellikle üretim sektöründe hammadde, stok, yarı mamul, yedek parça, insan gücü ve yatırımla ilgili ihtiyaçların birçoğunun belirlenmesinde talep tahminine başvurulmaktadır. Üretim planlaması yapılırken eğer talep tahmini söz konusu ise geçmiş verilerin bilinmesi ve doğruluğu işletmeler için oldukça önemlidir. Mevcut olan bu verilere göre üretim adetlerinin tahminleri yapılacaktır. Bu tahminler yapılırken talebi etkileyen değişkenlerinde belirlenmesi gerekmektedir. Böylelikle gelecek ile ilgili doğruya yakın yapılan talep tahminleri üretim planlama için iyi birer girdi olacaktır. Bu nedenle firmalar iyi bir planlama ve gerçeğe yakın yapılan talep tahmini ile maliyetleri azaltarak maksimum müşteri memnuniyetine ulaşmayı hedeflemektedir.

Talep tahmin dönemleri kapsadıkları zaman aralıklarına göre 4 döneme ayrılır (Tekin, 1996).

- Çok Kısa Dönemli Tahminler; Çoğunlukla haftalık ya da günlük yapılan tahminlerdir. İş planı hazırlamak, stokların kontrolü örnek verilebilir.
- Kısa Dönemli Tahminler; 1aydan 6 aya kadar yapılan tahminlerdir. Sipariş adetlerinin belirlenmesi örnek olarak verilebilir.
- Orta Dönemli Tahminler; 6 aydan 5 yıla kadar olan tahminlerdir. Tedarik süreleri uzun aynı zamanda belirsiz olan ürünlerin temini planlanırken kullanılabilir.
- Uzun Dönemli Tahminler; 5 yılın üzeri yapılan tahminlerdir. Bütçe planlamaları, yatırım planlamaları bu gruba örnek verilebilir.

Bir sonraki bölümlerde talep tahmin aşamaları ve talep tahmin yöntemlerinden detaylıca bahsedilecektir.

3.2. Talep Tahmin Aşamaları

Talep tahmini yapılırken gerçekleşen temel 6 aşama ve açıklamaları aşağıdaki gibidir:

1.Aşama: Talep Tahmininin Amacının Belirlenmesi

Talep tahmin sürecinin birinci adımı talep tahmininin amacının belirlenmesidir. Firmalar tahmin yapacağı ürün grubunu ve tahmin çeşidini açıkça belirlemelidir.

2.Aşama: Talep Tahmin Döneminin Belirlenmesi

Talep tahminleri çok kısa dönem, kısa dönem, orta dönem ve uzun dönem için yapılabilir. Tahmin çalışmasına başlamadan önce döneminin belirlenmesi talebi etkileyen değişkenler açısından önem arz etmektedir.

3.Aşama: Talebi Etkileyen Değişkenlerin Belirlenmesi

Bir sonraki dönemin talebini etkileyen birçok farklı faktör olabilir. Mevsimler şartlar, aylar, kur etkisi, dünyada artan nüfus sayısı, ürünün fiyatı, pazardaki rakip firma sayısı gibi faktörlerden etkilenebilir. Çalışmanın yapıldığı sektöre ve müşteri ihtiyaçlarına göre bu faktörlerin doğru belirlenmesi oldukça önemlidir.

4.Aşama: Verilerin Toplanması

Talep tahmininin bu aşamasında talep tahmini yapılacak ürün grubu ve tahmini etkileyen değişkenler için veriler toplanıp gerekli analizler ve kontroller yapılır. Hatalı ya da eksik veriler olduğunda tekrar bu aşama gözden geçirilmelidir.

5.Aşama: Talep Tahmin Yönteminin Seçilmesi

Talep tahmin yöntemi seçilirken verilerin büyüklüğü, tahmin yapılacak zaman aralığı değerlendirilerek tahmin yöntemine karar verilir. Talep tahmin yöntemleri iki ana gruba ayrılır. Bunlar, kalitatif ve kantitatif yöntemlerdir. Kalitatif tahmin yöntemi, istatistiksel yöntem kullanılmadan insanların sezgisel yaklaşımlarına dayalı yapılan bir talep tahmin yöntemidir. Kantitatif tahmin yöntemi ise istatistiksel yöntemler kullanılarak yapılan yöntemlerdir.

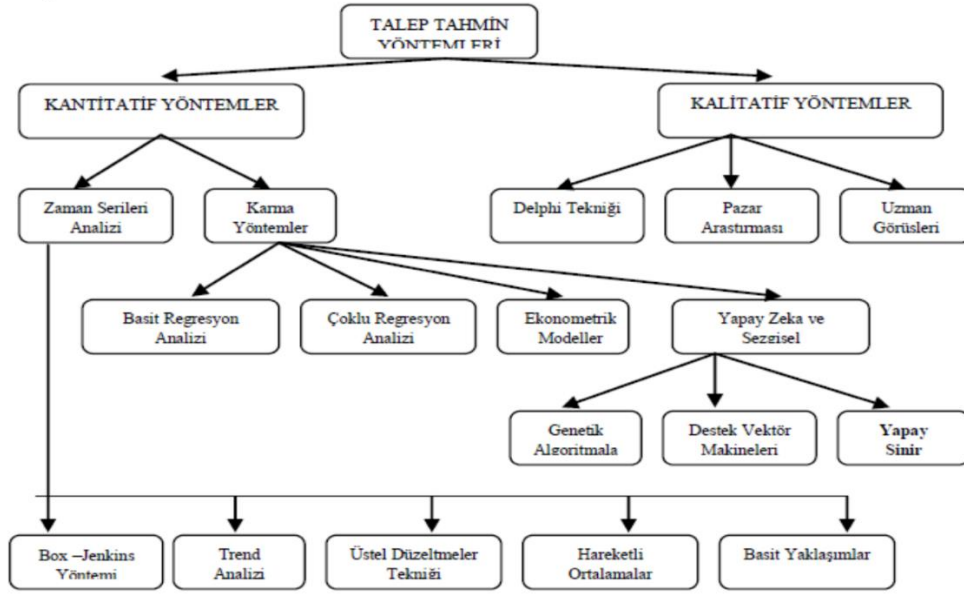
6.Aşama: Tahmin Sonuçlarının Değerlendirilmesi

Yapılan tahminler sonucunda elde edilen veriler ile gerçek değerler karşılaştırılır. Tahmin değerleri ile gerçek değerler arasındaki sapmaların az olması beklenir. Böyle olmadığı durumlarda veriler ve yöntem tekrar gözden geçirilebilir.

3.3. Talep Tahmin Yöntemleri

Tahmin, mevcut olan verilerle gelecek ile ilgili öngöründe bulunmaktır. Talep tahmini ise gelecekte belirli bir zamandaki ürün ya da hizmete olan satın alma arzusunun geçmiş ve mevcut verilerle çeşitli yöntemler kullanılarak tahmin edilmesidir.

Üretilen ürün ya da hizmete göre müşteri davranışları değişebileceğinden dolayı talep yöntemleri de değişiklik gösterebilir. Talep tahmin yöntemlerini iki bölüme ayırabiliriz. Bunlar; kalitatif ve kantitatif yöntemlerdir. Kalitatif yöntemler, matematiksel olmayan daha çok insanların sezgisel yaklaşımlarına dayanan yöntemlerdir. Kantitatif yöntemler ise istatistiksel hesaplamalara dayanan yöntemlerdir. Şekil 3.1’de talep tahmin yöntemlerinin çeşitleri görülmektedir.



Şekil 3.1. Talep tahmin yöntemleri (Türk ve Kaini, 2019)

3.3.1. Kalitatif Yöntemler

İstatistiksel yöntemler kullanmak yerine, insanların deneyimlerine ve sezgisel yaklaşımlarına göre yapılan tahminlerdir. Matematiksel hesaplamalar içermediğinden dolayı öznel yaklaşımlardır. Bu yöntemlerden en yaygın kullanılanları aşağıda özet şekilde sunulmuştur.

3.3.1.1. Yönetici Görüşlerinin Alınması

İdari yöneticiler, mali işler, üretim ve satın alma gibi bölümlerin yöneticileri ve satış personellerinin deneyimleri ve bilgileri dikkate alınarak yapılan tahminlerdir. Tamamen karar verilerin kişisel görüşleri dikkate alınarak yapılan tahminler olmasından dolayı tahmin performansının iyi olma ihtimali düşüktür.

3.3.1.2. Anketler

Firmalar tarafından belirli bir ürün ya da hizmetin talebini tahmin etmek için, bir tüketici grubunu örneklem olarak seçerek anketler yapılır. Anketlerin sonuçlarından elde edilen veriler istatistiksel yöntemlerle değerlendirilerek gelecekle ilgili tahminlerde bulunulur.

3.3.1.3. Delphi Yöntemi

Delphi yöntemi, kısa ve uzun dönemli olayların ortaya çıkmasına dayalı tahminlerde kullanılan bir araştırma türüdür. Bu yöntem ile çok sayıda anket gönderilerek geri

besleme yoluyla katılımcıların ortak bir fikre ulaşmaları sağlanır. Bundan dolayı bu yöntem ile uzmanların yüz yüze gelmesine gerek kalmadan grubun karar alması sağlanır (Seaton ve Bennet, 1996). Delphi yönteminin avantajları ve dezavantajları aşağıdaki gibidir;

Avantajları;

- Grup üyelerinin bir araya geldiklerinde birbirlerinin düşüncelerinden etkilenme gibi bir durumu ortadan kaldırmaktadır.
- Üyelerin maliyet, zaman, mesafe gibi nedenlerden dolayı istedikleri zaman bir araya gelememe durumunu ortadan kaldırmaktadır.

Dezavantajları;

- Sonuca ulaşmanın zaman alması
- Sürecin uzun olmasından dolayı katılımcı sayısının çok olmaması
- Yöntemin iyi sonuçlar vermesinin grup üyelerinin seçimlerine bağlı olması

3.3.1.4. Pazar Araştırması

Pazar araştırması, belirli bir ürün grubu ya da hizmet için potansiyel müşterilerin görüşlerini almaktır. Firmalar ürünü ya da hizmeti sunacakları piyasanın kapsamı, büyüklüğü ve satın alma davranışları ile ilgili bilgi sahibi olmak ve tahminlerini buna göre yapmak isterler. Bunun için çoğu firmanın satışları ile ilgili tahmin yapmada başvurduğu yöntemlerin başında pazar araştırması gelmektedir.


3.3.2. Kantitatif Yöntemler

Kantitatif yöntemler, geçmiş dönemlerin verileri kullanarak gelecekle ilgili yapılan tahminlerin istatistiksel yöntemlerle hesaplanmasıdır. Zaman serileri analizi ve nedensel yöntemler olmak üzere 2 ana gruba ayrılır. En çok kullanılan kantitatif tahmin yöntemleri şunlardır (Tekin, 1996):

3.3.2.1. Zaman Serileri Analizine ile Talep Tahmin Yöntemleri

Bu analiz, firmaların gelecekle ilgili tahminler yaparken geçmiş satış verilerinin incelenerek bunlara ilişkin belirli bir eğim olup olmadığının incelenmesidir (Karahana, 2011). Zaman serileri analizlerinin amacı geçmiş verilere göre geleceğin tahmin edilmesidir (Üreten, 2005).

Analiz yapılırken belirli bir döneme ait talep ile ilgili bilgiler bir ölçüğe göre sıralanır ve elde edilen talep doğrusunun nasıl bir eğim gösterdiğine bakılır. Elde edilen sonuca göre talebin bir eğim gösterdiği, sabit olduğu veya mevsimler değişimleri geçirdiği gözlemlenebilir (Ballı, 2014). Zaman serileri analizinde ortalama talepte uzun süreli bir artma veya azalma görüldüğü takdirde bir eğim söz konusu olabilir. Talep düzeyinde uzun dönemli bir eğim tespit edildiğinde bu sonuca göre bir talep beklentisi olacaktır (Üreten, 2005). Şekil 3.2’de çeşitli talep düzenlerinin zamana göre değişimi görülmektedir.



Şekil 3.2. Çeşitli talep düzeylerinin zamana göre değişimi (Üreten, 2005)

Zaman serileri analizi uygulanırken izlenen aşamalar aşağıda sunulmuştur (Ballı, 2014).

1. Adım: Seri iki eş parçaya ayrılır.
2. Adım: Tahmin yöntemi uygun metot içerisinde seçilir.
3. Adım: Tahmin yöntemi başlangıç verileri kullanılarak başlatılır.
4. Adım: Her bir tahminden sonra hatalar hesaplanır ve farklı veri örnekleri için yöntemin uygunluğuna bakılır.

3.3.2.1.1. Son Dönem Talep Yöntemi

Bu yöntemde, son dönemin talebi gelecek yeni dönemin de talep tahmini olmaktadır. Bu yöntem geçmiş veriler çok değişkenlik göstermediğinde ve bir ortalama değerde sürekli ve az değişim gösterdiğinde tercih edilmelidir.

3.3.2.1.2. Basit Ortalamalar Yöntemi

Bu yöntem bir serideki toplam verinin gözlem adetlerine bölünmesiyle elde edilmektedir. Geçmiş verilerde artma veya azalma olmadığı durumlarda, gelecek ile ilgili büyük değişikliklerin beklenmediği durumlarda bu tahmin yöntemi kullanılabilir. Fakat devam eden dönemlerde artma veya azalma eğilimi görülürse; gerçekleşen talep öngörülen talepten aynı yöne giderek sapmaların artmasına sebep olacaktır.

3.3.2.1.3. Hareketli Ortalamalar Yöntemi

Hareketli ortalama yöntemi mevsimsel dalgalanmaların talep üzerindeki etkisi incelenmek istediğinde kullanılan tahmin yöntemidir. Geçmiş dönemdeki satış verileri incelenir ve satış adetlerinin zamanla gösterdiği eğilimden yararlanılarak gelecek dönem için satışların talep tahmini yapılır. Bu yöntemin en temel özelliği mevsimsel dalgalanmaların talep üzerindeki etkisinin belirgin bir şekilde ortaya çıkmasıdır. Genellikle 3 ay, 4 ay, 6 ay ve 12 aylık ortalamalara göre değerlendirilir. (Adıyaman, 2007).

Bu yöntemde talep tahmini yapılacak dönemden n dönem önceki taleplerin ortalaması alınarak hesaplamalar yapılır. Bu işlemler aşağıda eşitlik 3.1 de gösterilmiştir.

$$S_t^* = \frac{\sum_{i=1}^n S_{t-i}}{n} \quad (3.1)$$

S_t^* : t. dönemdeki talep tahmin

S_{t-i} : i. dönem öncesindeki talep değeri

n: dönem sayısıdır.

Bu yöntem, talebin arttığı dönemlerde düşük tahmin değerini azaldığı dönemlerde ise yüksek tahmin değeri ortaya çıkarır.

3.3.2.1.4. Ağırlıklı Ortalamalar Yöntemi

Ağırlıklı ortalamalar yöntemi en yakın geçmiş dönem verilerinin gelecek dönem ile ilgili fikir verdiği durumlarda kullanılan yöntemlerdir. Bu yöntemde geçmişteki verilerin ortalamaya olan etkisi farklıdır. Geçmiş veriler ile ilgili hesaplamalar yapılırken en son dönemdeki verilere daha çok ağırlık verilmesi istenildiğinde bu yöntem başvurulur. Ağırlıklı ortalamalar yöntemi için talep tahmini hesaplamaları aşağıdaki gibidir:

$$S^* = \frac{\sum_{i=1}^n S_i W_i}{\sum_{i=1}^n W_i} \quad (3.2)$$

Eşitlik 3.2'de,

S^* : Talep tahmini değeri

S_i : i. dönemdeki talep değeri

W_i : i. Dönemdeki talebin tahmine etkisi

N= Geçmiş dönem sayısıdır.

3.3.2.1.5. Ağırlıklı Hareketli Ortalamalar Yöntemi

Bu yöntemde ağırlıklı ortalama yöntemindeki gibi tahmin yapılan dönemler önceki döneme göre ağırlıklandırılır. Ağırlıklı ortalama yönteminden farklı olarak geçmişle ilgili tüm verileri almak yerine en yakın dönemin değerleri dikkate alınarak yapılır. Hesaplama yapılırken geçmiş en yakın dönemin talebine ağırlık verilir. Dönem sayısı değiştikçe talep tahmininin değeri de değişiklik göstermektedir. Bu yöntem uygulanırken talep tahmin değeri aşağıdaki gibi hesaplanır.

$$S_t^* = \sum_{i=1}^n (W_i S_{t-i}) \quad (3.3)$$

S_t^* : t. dönemdeki talep tahmin değeri

S_{t-i} : i dönem öncesindeki gerçekleşen satış değeri

W_i : i. dönemdeki ağırlık katsayısı

n : dönem sayısı

$0 < W_i < 1$ (i=1,2,...,n) olmalıdır.

3.3.2.1.6. Üssel Ağırlıklı Ortalama (Üssel Düzeltme) Yöntemi

Üssel ağırlıklı ortalama yönteminde geçmiş bütün verilere farklı ağırlıklar verilir. Basit hareketli ortalamalar yönteminden farklı geçmiş verilere farklı ağırlıklar verilmesidir. Bu yönteme dönemler azaldıkça verilerin ağırlıklarında azaldığından dolayı üssel düzeltme yöntemi denilmektedir. Üssel Ağırlıklı Ortalama yönteminin hesaplanmasında kullanılan formüller aşağıdaki gibidir.

$S_t = (t + 1)$ için t anında yapılan talep tahmini,

$D_t = t$ anında gerçekleşen talep

$S_{t-1} = t-1$ zamanında talep tahmini

α = düzeltme katsayısı

$$S_t = \alpha D_t + (1-\alpha) S_{t-1} \quad (3.4)$$

şeklinde hesaplanmaktadır. Düzeltme katsayısının değeri 0 ile 1 arasında değişmektedir. Eğer düzeltme katsayısının (α) değeri büyük ise bu son dönemin verilerinin ağırlığının arttığını, eğer küçük ise bu da geçmiş verilerin ağırlığının arttığını göstermektedir.

3.3.2.2. Karma (Sebeup-Sonuç İlişisine Dayanan) Yöntemler

Bağımlı ve bağımsız değişkenler arasındaki ilişkiyi ölçmede kullanılan istatistiksel yöntemlerdir. Bu yöntemlerden en çok kullanılanları regresyon analizi, Korelasyon analizi ve BoxJenkis yöntemleridir.

3.3.2.2.1. Regresyon Analizi

Regresyon analizi, aralarında neden-sonuç ilişkisi olan değişkenler aralarındaki ilişkiyi ölçerek tahmin çalışmalarında kullanılan istatistiksel bir yöntemdir. Burada bağımlı değişkenler ile bağımsız değişkenler arasındaki ilişkiyi kuran parametre değerleri tahmin edilir (Çağlar, 2007). Bu analiz yardımıyla hangi faktörlerde nasıl bir değişiklik yapılırsa ilgili değişkende artma ya da azalma olacağı ortaya çıkmaktadır (Hanke ve Reitsch, 1992). Bu yöntemde, Y bağımlı değişken, X_1, X_2, \dots, X_n bağımsız değişkenlerdir.

En az iki değişken olduğunda aralarında eğrisel veya doğrusal ilişki bulunur. Temelde üssel regresyon, eğrisel regresyon, basit doğrusal regresyon ve oklu doğrusal regresyon denklemleri bulunmaktadır (Çağlar, 2007). Bu regresyon denklemlerin gösterim şekilleri aşağıda sunulmuştur.

Üssel: $Y = a + b_1^x$ (3.5)


Basit Doğrusal: $Y = a + bX$ (3.6)

Çoklu Doğrusal: $Y = a + b_1X_1 + b_2X_2 + \dots + b_nX_n$ (3.7)

Eğrisel : $Y = a + b_1X + b_2X^2 + \dots + b_nX^n$ (3.8)

Bu yöntem, iki değişkenli olduğu zaman aralarındaki ilişki doğrusal kabul edilmektedir ve $Y_i = a + bX_i + e$ biçiminde gösterilir. Burada bağımsız değişken değeri


yerine konularak tahmin değeri hesaplanır. Aşağıdaki şekilde verildiği gibi bağımlı değişken değeri ve gerçek değer arasındaki farkların karelerinin toplamını en az yapacak şekilde uygun olan doğru belirlenir (Karahana, 2011).



Şekil 3.3. Regresyon doğrusu (Karahana, 2011)

3.3.2.2.2. Korelasyon Analizi

Regresyon bağımlı değişkenlere göre bağımsız değişkenin alacağı değeri gösterirken korelasyon denklemi ise iki değişkenin aralarındaki ilişkinin derecesini ve doğrunun uygunluğunu ölçmektedir. Bu aradaki ilişkinin derecesi ne kadar fazla ise tahminin doğruluğu da o derecede güçlüdür. İki değişkenin aralarındaki ilişkinin derecesi korelasyon katsayısı (r) türünden ifade edilir.



Şekil 3.4. Korelasyon katsayısı eğrisi (Karahan, 2011)

Şekil 3.4’te gerçekleşen Y tahmin değerleri arasındaki ilişkiyi gösteren eğrinin grafiği verilmiştir. Grafiğe göre değişkenler arasındaki ilişkinin 1 den az olması, korelasyon katsayısı (r) ise -1 ile 1 arasında olması beklenir. Aşağıda korelasyon katsayısının aldığı değerlere göre değişkenler arası ilişki yorumlanmıştır.

Çizelge 3.1. Korelasyon katsayısı değerleri ve yorumlanması (Tekin, 2009)

Katsayısı Değeri	Korelasyon Yorumları
0,00- 0,2	Çok düşük ilişki
0,2-0,4	Düşük ilişki
0,4-0,7	Normal ilişki
0,7-0,9	Yüksek ilişki
0,9-1	Çok yüksek ilişki

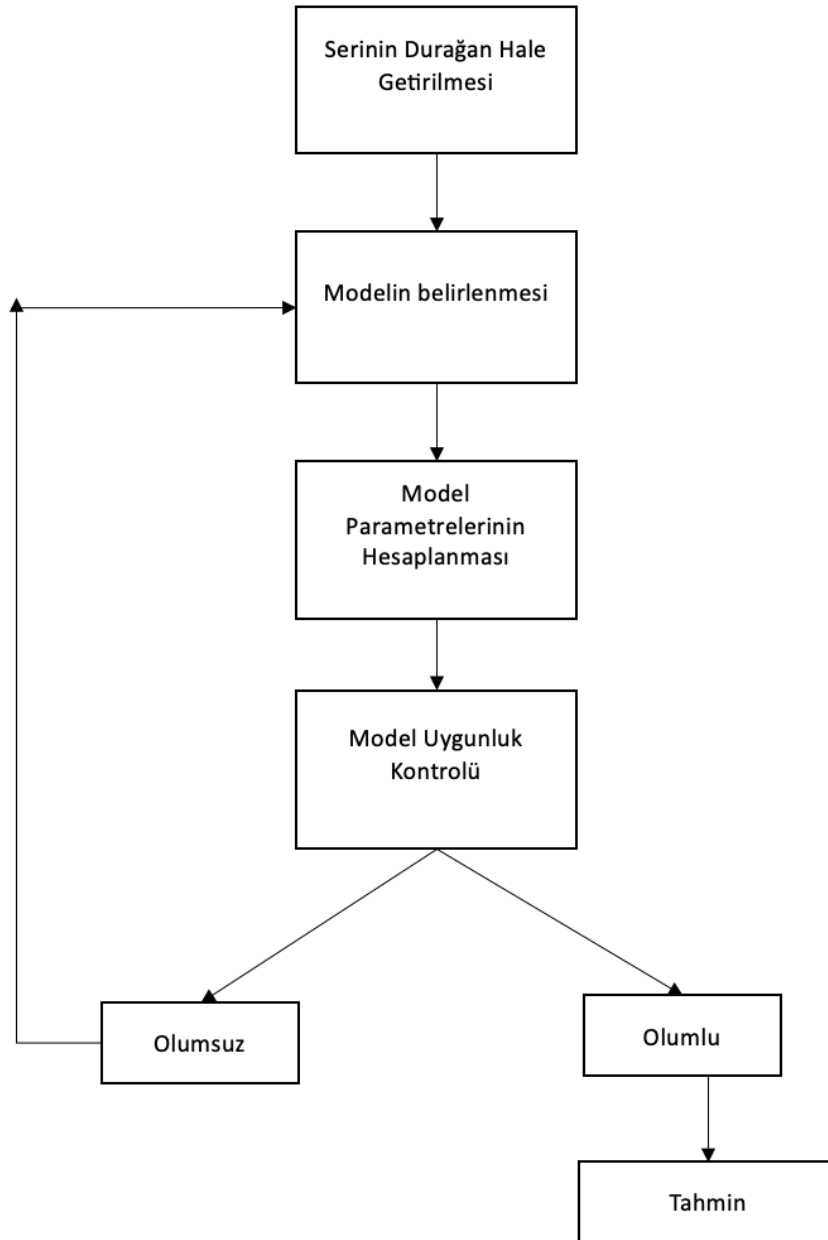
Çizelge 3.1’ de görüldüğü gibi korelasyon katsayısının değeri 1 ‘e yakın olması aralarındaki ilişkinin ne kadar güçlü olduğunu göstermektedir. Tam tersi 0’a yakın olamasa ise aralarındaki ilişkinin çok zayıf olduğunu göstermektedir. Korelasyon katsayısının değeri, -1 ile 1 arasında olmalıdır. Eğri denklemindeki x ve y değerleri beraber artıyorsa pozitif, biri artıp diğeri düşüyorsa negatif bir ilişkiden bahsedilir. Yani +1’e yakın korelasyon katsayısı aralarına pozitif bir ilişki, -1’e yakın olması ilişkinin negatif olduğunu, 0 ise aralarında bir ilişki olmadığını göstermektedir.

3.3.2.2.3. Box Jenkins Yöntemleri

Bu yöntem tek bir değişkenden oluşan modellerdir ve kısa dönemli tahminlerde başarılı sonuçlar verir. Amaçlanan, az sayıda parametreler ile uygun modeller elde etmektir. Üssel düzeltme ya da Hareketli ortalama tekniklerine göre daha karmaşık ve

anlaşılması güçtür. Yöntem, serinin durağanlığına ve mevsimsel etki içermesine göre değişik şekillerde tahmin modelleri geliştirme özelliğine sahiptir.

Şekil 3.5'te de modelin aşamalar görülmektedir. Burada ilk olarak durağan seriler seçilmeli ya da seriler durağan hale getirilip en uygun Box-Jenkins modeli belirlenmelidir. Daha sonra parametreler belirlenir ve model istatistiksel yöntemlerle hesaplamalar yapılır. Model uygunluğu test edilip olumlu sonuçlar alınırsa diğer aşamaya geçilir, uygun değilse yeniden model belirlenir ve işlemler kontrol edilir.



Şekil 3.5. Box-Jenkins metodolojisi (Hyndman, 2001)

- AR-MA ve ARIMA Modelleri

Otoregresif Hareketli Ortalamalar (AR-MA) modeli zaman serisinde herhangi döneminde elde edilen gözlem değerleri, bahsedilen dönemden önceki belli sayıda gözlem değeri ve hata teriminin birleşimidir.

Otoregresif (AR) sürece zaman içerisinde verilerin değişmemesi durumudur. Hareketli Ortalamalar (MA) ise serideki gecikmeli hata teriminin şimdiki hata terimini etkilemesi şeklinde ifade edilebilir.

Otoregresif Bütünleşik Hareketli Ortalamalar modeli (ARIMA) ise zaman serileri temelli, çok değişkenli bir modeldir. ARIMA modeli, geçmiş verileri kullanarak gelecek ile ilgili matematiksel tahminler yapabilmektedir (Chung, 2001: 17). ARIMA modelleri kısa - orta dönem tahminlerde oldukça başarılı olması nedeniyle yaygın bir kullanım alanına sahiptir (Olgun, 2009)

3.3.2.2.4. Yapay Zekâ Yöntemleri

Yapay Zekâ (YZ) ile ilgili yapılan bazı tanımlar şu şekildedir (Pirim, 2006).

- YZ insanların zeki olarak betimlediği davranışların makine tarafından yapılmasıdır.
- YZ, insan beyninin çalışma şeklini göstermeyi amaçlayan bir sistemdir.
- YZ' nin amacı, bilgisayar aracılığıyla insan zekasının taklit edilmesidir.
- YZ, zekanın yapısını anlayabilmek için bilgisayar programları oluşturur.
- YZ, insan olmadan kompleks işler yapabilir.

• Genetik Algoritmalar (GO)

Genetik algoritmalar (GO), doğal seçim ilkelerine dayanan bir optimizasyon ve arama yöntemidir. GO, fonksiyon optimizasyonu, mekanik öğrenme, çizelgeleme, hücresel üretim, tasarım gibi alanlarda iyi sonuçlar veren uygulamaları bulunmaktadır (Emel ve Taşkın, 2002).

Genetik algoritmalar, yapay zekanın hızla gelişen dallarından biridir. Bu yöntem günlük hayatta karşılaştığımız çözümü zor ve karmaşık problemlerin hesaplanmasında kullanılan yapay zekâ tabanlı yöntemler arasındadır.

GO, doğal seçim ilkelerine dayanan bir optimizasyon yöntemidir. Geleneksel yöntemlerine göre farklılıkları vardır. Bu yöntemin arama yapması alt dizi kavramlarıyla açıklanır. Alt diziler ile algoritmaların davranışları açıklanır. Alt diziler belirli bir dizi kümesinin arasındaki benzerliği tanımlar. Alt dizilerin özellikleri,

derecesi ve uzunluğudur. Genetik algoritmalar çözüm uzayında bulunan noktalarda kromozomlar ile kodlanır ve her noktanın bir uygunluk değeri vardır.

Genetik algoritmaların aşamaları aşağıdaki gibidir:

1.Aşama: Arama uzayında bulunan bütün mümkün çözümler dizi olarak kodlanmaktadır.

2.Aşama: Çoğunlukla rassal olarak çözüm kümesi belirlenir. Bu çözüm kümesi başlangıç popülasyonu olarak alınır.

3.Aşama: Bütün diziler için uygunluk değerleri bulunur.

4.Aşama: Bir grup dizi rassal olarak seçilerek belirli bir olasılığa göre çoğalır.

5.Aşama: Çaprazlama ve mutasyon işlemleri yapılır.

6.Aşama: Amaç fonksiyonuna en uygun dizi seçilene kadar iterasyon devam eder.

- Destek Vektör Makineleri (DVM)

DVM yöntemi; regresyon, sınıflandırma, zaman serileri ve karakter tanıma gibi birçok alanda kullanılmaktadır. Doğrusal olmayan problemlerin çözümünde kullanılan optimizasyon temelli bir algoritmadır. Diğer makine öğrenmesi yöntemlerinden farklı olarak çok sayıda veriye gereksinim duymaz.

Öncelikle sınıflandırma amacıyla kullanılan bu yöntem ayrıca regresyon ve zaman serileri modellerinde kullanılmış ve iyi sonuçlar alması nedeniyle kullanım alanları yaygınlaşmıştır (Bilisik, 2011).

- Yapay Sinir Ağları (YSA)

YSA'nın çalışma şekli insan beynini taklit ederek, öğrenme, hatırlama, genelleme yapma gibi insana özgü yetenekler kazandırılarak gerçekleştirilen yapay zekâ tabanlı bir yöntemdir. Genellikle sınıflandırma, örüntü tanıma ve tahmin olmak üzere birçok alanda kullanılmaktadır.

Gerçek hayatta doğrusal olmayan problemler ile karşılaşıldığında geleneksel yöntemler ile çözümlenmek oldukça zordur. YSA'nın en önemli özelliklerinden birisi doğrusal olmayan gerçek problemlerin çözümünde iyi sonuçlar veren yapılar olmasıdır.

Dördüncü bölümde yapay zekâ tabanlı yöntemlerden olan DVM ve YSA yöntemleri detaylı bir şekilde incelenmiştir.

3.4. Talep Tahmin Yöntemlerinin Doğruluğunun Ölçülmesi

Hangi tahmin yöntemi kullanıldığı farketmeksizin elde edilen sonuçlar ile gerçek veriler %100 tutarlı değildir. Yani her tahmin sonucunda belirli bir hata oranı kesinlikle vardır. Bu sebeple tahmin çalışmasının doğruluğunun test edilmesi gerekmektedir. Gerçek değerler ile tahmin sonucunda elde edilen çıktılar arasındaki sapmalar tahmin hatasını vermektedir.

$$h_t = V_t - E_t \quad (3.9)$$

V_t = t zamanında gerçekleşen talep

E_t = t zamanında tahminin değeri

h_t = tahmin hatası

Tahmin doğruluğunun ölçülmesinde sık kullanılan yöntemler aşağıda verildiği gibidir:

- Ortalama Hata Karesi (Mean Squared Error- MSE)

MSE, talep tahminin doğruluğunun hesaplanırken en sık kullanılan yöntemlerdendir. Hesaplama yapılırken hata değerlerinin ortalaması alınır. Ortalama hata karesinin hesaplanma şekli aşağıdaki gibidir:

$$MSE = \frac{1}{n} \sum_{i=1}^n h_i^2 \quad (3.10)$$

- Ortalama Mutlak Hata (Mean Absolute Error- MAE)

Bu yöntemde hataların mutlak değerleri alınır ve negatiften arındırılır. Hesaplama yapılırken mutlak hata değerlerinin aritmetik ortalamasını aldığından dolayı sonuçlar daha olumludur. MAE' nin hesaplanması aşağıdaki gibidir:

$$MAE = \frac{1}{n} \sum_{i=1}^n |h_i| \quad (3.11)$$

- Ortalama Mutlak Yüzde Hata (Mean Percentage Absolute Error- MAPE)

Bu yöntemde hatalar yüzde biçiminde gösterilir. Bu hesaplama yapılırken her bir periyot için mutlak hata değerleri gerçek değerlere bölünerek yüzdesi alınır.

Ortalama mutlak yüzde hata ölçütünde sonuçların yüzde olarak alınması yöntemin yorumlanmasını ve anlaşılır olmasını sağlamaktadır. Bu nedenle talep doğruluğu ölçülmesinde çok tercih edilmektedir.

Bu yöntemin hesaplanması aşağıdaki gibidir:

$$MAPE = \left[\frac{1}{n} \sum_{i=1}^n \frac{|h_i|}{v_t} \right] * 100 \quad (3.12)$$

4. YAPAY ZEKÂ İLE TALEP TAHMİN YÖNTEMLERİ

4.1. Yapay Sinir Ağları (YSA)

4.1.1. Yapay Sinir Ağları Tanımı

Tarih boyunca insan beyninin nasıl çalıştığını bilmek hep merak konusudur. Günümüzdeki birçok teknolojik aletlerde bu merak konusundan günümüze gelmiştir. İlk olarak icat edilen bilgisayardan insanların beklentisi hesap yapmak iken günümüzde bu durum daha ileri giderek beyin gücü gerekecek işleri yapmasına kadar gelmiştir. Bu durumda ise karşımıza yapay sinir ağları çıkmaktadır. Yapay sinir ağları (YSA) insanın beynindeki bilgileri analiz eden ve işleme şeklini simüle eden bir bilgisayar sistemidir. İstatistiksel hesaplamayla zor olan sorunları çözen YSA, veri sayısını ne kadar arttırırsak o kadar iyi sonuçlar elde edebileceğimiz bir modeldir. Bunun sebebi ise bu modelin kendi kendine öğrenme yeteneğine sahip olmasıdır.

4.1.2. Yapay Sinir Ağlarının Genel Özellikleri

YSA'nın karakteristik özellikleri uygulanacak olan ağın modeline göre değişiklik göstermektedir. Bütün modellerde geçerli olan bu özellikler ise aşağıdaki gibidir (Öztemel, 2016).

- YSA makine öğrenmesi gerçekleştirir: Bu model bilgisayarların öğrenmesini sağlayarak benzer olaylara benzer kararlar vermeye çalışır.
- YSA, kendi kendine öğrenebilme yetenekleri sayesinde genelleme yapabilir.
- Programları diğer çalışma stili bilinen programlama yöntemlerinden farklıdır.
- Hata toleransları vardır: Ağın eksik bilgilerle çalışmasından dolayı hata toleransı vardır. YSA bu toleransı sayesinde bazı hücrelerin çalışmaması durumunda bile genel fonksiyonunu yerine getirebilmektedir.
- YSA örnekleri kullanarak öğrenir: Örnekleri kullanırlar ve genelleme yapabilecek bir duruma gelebilirler.

- Dereceli bozulma gösterirler: Hatalara karşı toleranslarının olmasından dolayı dereceli olarak bozulmalarda meydana gelmektedir. Bu durum hücrelerde bozulma ya da eksik olan bilgiden kaynaklıdır. Ağlar, bir problem meydana geldiğinde hemen bozulmazlar.
- YSA' nın en doğru şekilde çalışabilmesi için öncelikle eğitilmeleri ve performans testlerinin yapılması gerekmektedir.
- YSA kendisine daha önce gösterilen örneklerden bir genelleme yapar ve görmediği örnekler içinde bilgi üretebilir.
- YSA' da bilgi, ağın bağlantısının değerleriyle ölçülmektedir. Diğer programlardan farkı ise bilgiler veri tabanı veya programın içerisinde değildir. Burada bilgiler ağın üzerinde saklı olduğundan yorumlanması ve ortaya çıkarılması güçtür.
- Şekilleri ilişkilendirebilirler aynı zamanda sınıflandırmasını yapabilirler.
- Bilgi eksik dahi olsa çalışabilmektedirler: YSA eğitildikten sonra genelleme yapabilme yeteneği sayesinde eksik bilgi olduğunda da çalışabilir ve sonuç üretebilir.
- Tam olmayan ve belirsiz bilgileri işleyebilmektedirler.

4.1.3. Yapay Sinir Ağlarının Uygulama Alanları

YSA' nın farklı birçok alanda uygulaması yapılmış ve başarılı sonuçlar elde edilmiştir. İlk çalışmalar yaklaşık elli yıl önce başlamış olsa bile en aktif kullanımı son yirmi yılda başlamıştır. Yapılan bu çalışmaların çoğu tahmin ve finansal analiz, örüntü sınıflandırma ve kontrol ve optimizasyon kategorilerindedir. YSA, günümüzde çözümü karmaşık olan farklı alanlarda problemlerin çözümü için kullanılmıştır. Bunlardan bazıları ise aşağıdaki gibidir.

Tahmin: Yapay sinir ağlarının girdi bilgilerini kullanarak çıktı verilerini tahmin etmesidir. Birçok alanda tahmin yöntemi için YSA kullanılabilir. Hava durumu tahminleri, satış tahminleri, borsadaki hisselerin değerleri, iflas tahmini, kredi derecelendirme, fiyat tahminleri, döviz kurlarının tahmini ve birçok alanda YSA kullanarak tahmin yapmak mümkündür.

Sınıflandırma: YSA girdi bilgilerini kategorize edebilirler. Böylece hatalar, müşteri/pazar profilleri, hücrelerin sınıflandırılması gibi birçok alanda YSA modeli kullanılabilir.


Veri ilişkilendirme: Ağa sunulan verilerde bir hata ya da eksik olup olmadığını belirlerler. Öğrendiği bilgiler sayesinde eksik belgeleri tamamlar ve en güvenilir sonucu verir.

Tıp alanı: YSA, kanserli hücrelerin belirlenmesi, hastane giderlerinin optimizasyonu, protez tasarımı gibi birçok tıp alanında da kullanılmaktadır.

Yapay sinir ağlarının bazı kullanım yerleri yukarıda bahsedilmiştir. YSA, günümüzde karşılaşılan problemlerde geniş bir uygulama alanına sahiptir. Günümüzde endüstri dalında öngörü ve modelleme konularında yaygın bir şekilde kullanılmaktadır.

4.1.4. Yapay Sinir Ağının Yapısı ve Temel Elemanları

- **Biyolojik Sinir Hücreleri**



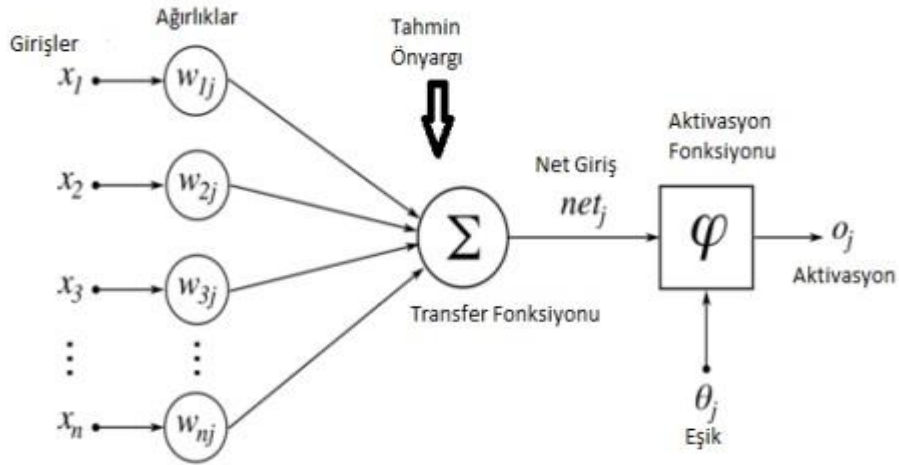
Şekil 4.1. Biyolojik sinir ağı hücresi (Maltarollo vd., 2013)

YSA' nın daha anlaşılır olması için biyolojik sinir ağlarının çalışma şeklinin bilinmesi gerekir. Günümüzde insan beyninin bilgiyi işlemesi ve kendisini nasıl eğittiği konusunda kesin bir bilgi yoktur. Bilim insanlarının bu konu ile ilgili farklı teorileri bulunmaktadır. Bu teorilerin büyük bir çoğunluğuna göre insan beyni, birbiri ile ilişkili karmaşık milyarlarca nöron adı verilen sinir hücrelerinden oluşmaktadır. İnsan

beyninde milyarlarca sinir hücresi bulunmaktadır ve bu hücreler ortalama olarak 10.000 hücre ile bağlantılı bir şekilde çalışmaktadır.

Biyolojik sinir sistemi, bilgiyi alarak yorumlayıp ve kararlar üreten merkezlerdir. Nöronlar; hücre gövdesi, dendritler ve aksonlardan oluşmaktadır. Dendritler sinyalleri hücre gövdesine alıcılarıdır. Yapıları ağaç şekline benzeyen ağlardır. Hücre gövdesi, dendritlerden gelen sinyalleri toplarlar. Aksonlar hücre gövdesinde toplanan sinyalleri diğer sinir hücrelerine taşımakla görevli olan uzun yapılardır. Şekil 4.1 'in 3. bölümünde görüldüğü üzere hücrenin dendriti ile diğer bir hücrenin aksonunun bağlantı yerlerine sinaps denir. Sinapslar hücreler arasında elektrik sinyallerinin akışını sağlar. Ayrıca sinir ağının işlevini ve nöronların dizilimini sağlarlar.

- **Yapay Sinir Ağı Hücresi**



Şekil 4.2. Yapay sinir hücresi yapısı (Uslu, 2016)

Yapay sinir hücreleri biyolojik sinir hücrelerinden esinlenerek matematiksel modellerle kurulan algoritmalarıdır. Biyolojik sinir hücrelerinde olduğu gibi yapay sinir hücrelerinde de bir nöron diğer bir nöronun çıktısını ya da dışarıdan gelen başka bir uyarıyı girdi olarak alır. Daha sonra bu girdileri transfer veya aktivasyon fonksiyonları ile işlenir ve sonunda dışarıya ya da bir diğer nörona çıktı olarak iletir. Yani yapay sinir hücreleri biyolojik sinir hücrelerini taklit eden modellerdir. Bu iki model arasındaki ilişki çizelge 4.1'de verildiği gibidir.

Çizelge 4.1. Biyolojik sinir hücresi ve yapay sinir hücresi arasındaki ilişki (Efe ve Kaynak, 2000)

Biyolojik Sinir Hücresi	Yapay Sinir Hücresi
Sinir sistemi	Hesaplama sistemi
Sinir	Düğüm, İşlem elemanı
Sinaps	Bağlantı Ağırlıkları
Dendrit	Toplama fonksiyonu
Hücre Gövdesi	Etkinlik fonksiyonu
Akson	Sinir Çıkışı

• Yapay Sinir Ağlarının Yapısı

Yapay sinir ağlarının temel bileşenleri 5 tanedir. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılardır.

1. Girdiler

Girdi katmanı, YSA'nın dış dünyadan, başka hücrelerden, ya da kendisi tarafından elde ettiği bilgilerdir. Girdi katmanında girdi nöronları bulunur ve girdi nöronlarına gelen veriler ağırlıklar ile çarpılarak işlenmek için gizli katmana iletilir.

2. Ağırlıklar

Ağırlıklar, girdi ve gizli katman arasında ve nörondaki girdilerin matematiksel katsayılarıdır. Girdi ve nöronlar arasındaki iletişimi sağlarlar ve hücreye giren bilgilerin önemini ve etkisini gösterirler.

3. Toplama Fonksiyonu

Toplama fonksiyonu net girdilerin hesaplandığı fonksiyondur. Bu fonksiyon için farklı fonksiyon türleri kullanılabilen ancak bunlardan en yaygın olanı ağırlıklı toplam fonksiyonudur. Bu fonksiyonun çalışması şu şekildedir; hücreye giren her girdilerin kendi ağırlıkları ile çarpılıp toplanır ve ağa gelen net girdiler belirlenir. Fonksiyonun denklemi eşitlik 4.1 de gösterildiği gibidir.

$$\text{Net} = \sum_{i=1}^n G_i \cdot A_i \quad (i=1 \dots n) \quad (4.1)$$

G: girdiler A: ağırlıklar

n: girdi sayısını ifade etmektedir.

Çizelge 4.2. Toplama fonksiyon çeşitleri (Kölmek, 2012)

Net Giriş	Açıklama
<i>Çarpım</i> $Net\ Girdi = \prod_i G_i A_i$	Ağırlık değerleri ile girdi değerlerinin birbirleriyle çarpılmasıyla elde edilir.
<i>Maksimum</i> $Net\ Girdi = Max(G_i A_i), i = 1...N$	Ağırlıklar ile girdiler çarpılır, çarpılmış değerler birbirleri ile kıyaslanır ve en büyük olan değer sistemin net girdisi olur.
<i>Minimum</i> $Net\ Girdi = Min(G_i A_i), i = 1...N$	Ağırlıklar ile girdiler çarpılır, çarpılmış değerler birbirleri ile kıyaslanır ve en küçük olan değer sistemin net girdisi olur.
<i>Çoğunluk</i> $Net\ Girdi = \sum_i sgn(G_i A_i)$	Ağırlıklarla çarpılmış olan girdilerin işaret fonksiyonu alınır, bu değerler toplanır ve net girdi olarak sisteme sunulur.
<i>Kümülatif Toplam</i> $NET\ Girdi = Net(eski) + \sum_i^n G_i A_i$	Hücreye gelen bilgiler ağırlıklı olarak toplanır ve daha önce gelen bilgilere eklenerek hücrenin net girdisi bulunur.

Tabloda görüldüğü üzere bazen girdilerin sayısı bazen de girdilerin değerleri önemlidir. En uygun toplama fonksiyonu formülü bulunmamakla birlikte modele göre denemeler yapılarak belirlenmektedir.

4. Aktivasyon fonksiyonu


Bu fonksiyon net girdiyi kullanarak buna karşılık üretilen çıktıyı belirleyen fonksiyondur. Bu fonksiyonda da toplama fonksiyonundaki gibi çıktıyı hesaplarken kullanılan farklı formüller bulunmaktadır. Burada aşdaki işlem elemanlarının tamamının aynı fonksiyonu kullanmasına gerek yoktur. Bu durum çalışma yapan kişinin deneme sonuçlarına bağlı olarak değişiklik gösterebilir. YSA da çoğunlukla kullanılan aktivasyon fonksiyonu sigmoid fonksiyonudur. Sigmoid fonksiyonu

özellikle doğrusal olmayan problemlerin çözümünde sıkça tercih edilen bir fonksiyondur. Bu fonksiyon türevi alınabilir bir fonksiyondur.

Fonksiyon denklemi eşitlik 4.2 de gösterildiği gibidir.

$$F(NE\text{T}) = \frac{1}{1+e^{-NE\text{T}}} \quad (4.2)$$

Toplama fonksiyonlarında hesaplanmış olan girdi değeri eşitlik 4.2'deki gibi belirlenir.



Şekil 4.3. Sigmoid fonksiyonunun gösterimi (Yücesoy , 2011)

Çizelge 4.3. Aktivasyon fonksiyon çeşitleri (Gürsoy, 2012)

Fonksiyon Türü	Fonksiyon	Fonksiyonun Grafiği
Lineer (Doğrusal) Fonksiyon	$F(NE\text{T}) = NE\text{T}$	
Hiperbolik Tanjant Fonksiyonu	$F(NE\text{T}) = \frac{e^{NE\text{T}} + e^{-NE\text{T}}}{e^{NE\text{T}} - e^{-NE\text{T}}}$	
Sigmoid Fonksiyonu	$F(NE\text{T}) = \frac{1}{1 + e^{-NE\text{T}}}$	
Eşik (Basamak) Fonksiyonu	$F(NE\text{T}) = \begin{cases} 1, & NE\text{T} > t \\ 0, & NE\text{T} \leq t \end{cases}$	

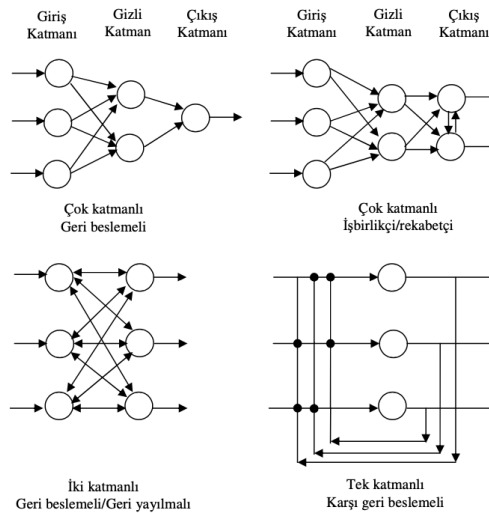
- Lineer (doğrusal fonksiyon); Bu fonksiyonda gelen girdiler, aynı zamanda hücrenin çıktısıdır.
- Hiperbolik tanjant fonksiyonu; Bu fonksiyonda net girdi değerlerinin tanjant fonksiyonunda geçmesi ile çıktı değerleri elde edilir. Bu çifti değerleri $[-1, 1]$ aralığındadır.
- Sigmoid fonksiyonu; YSA'da en sık kullanılan fonksiyondur. Sigmoid fonksiyonu sürekli artan bir fonksiyondur ve türevi alınabildiği için geri yayılım algoritmalarında sıkça kullanılır. Çıktı değerleri $[0, 1]$ aralığındadır.
- Eşik değer fonksiyonu; 0 veya 1'den büyük bilgilere göre bir değer alır. Genellikle tek katmanlı ağlarda kullanılır.

5. Çıktılar

Aktivasyon fonksiyonunun belirlediği çıktı değerleridir. Çıktılar başka bir fonksiyona ya da başka bir hücreye gidebilir. Bu çıktıları hücre kendisine girdi olarak gönderebilir.

4.1.5. Yapay Sinir Ağlarının Sınıflandırılması

YSA çok sayıda yapay sinir hücresinden oluşan katmanlı ağlardır. YSA'nın mimarisi katman sayısına, öğrenme stratejisine ve bağlantı yapılarına göre çeşitlilik göstermektedir.




Şekil 4.4. Yapay sinir ağı mimarisi (Kartalopoulos, 1996)

Şekil 4.4'te olduğu gibi ağlar tek katmanlı ve çok katmanlı olarak ayrılırlar. Genel olarak model; giriş tabakası, gizli katman ve çıkış tabakasından oluşmaktadır. Yapılarına göre; ileri beslemeli, geri beslemeli geri yayımlı ve geri beslemeli ağlar 3 gruba ayrılır.

- **İleri Beslemeli (Feed-Forward) Yapay Sinir Ağları**

Bu ağlarda, işlemciler katmanlara ayrılmıştır. Bilgi, girdi katmanı, gizli katman ve çıktı katmanı yönünde tek yönlü bağlantılarla iletilir. İşlemciler aynı katman içerisinde bağlantı kuramaz ancak bir katmandan diğerine geçerken bağlantı kurabilirler.




Şekil 4.5. İleri beslemeli yapay sinir ağı isleyişi (Güven, 2020)

Şekil 4.5' te ileri beslemeli YSA isleyişi blok diyagram olarak gösterilmiştir.

- **Geri Beslemeli (Feedback) Yapay Sinir Ağları**

Geri beslemeli ağlarda işlemciler arasında geri besleme bağlantıları vardır. Burada herhangi bir hücrenin çıktısı direkt girdi katmanına giderek yeniden girdi olarak kullanılabilir (Zhang, 2003). Bu yöntemin pratikte uygulamasının zor olmasından dolayı ileri beslemeli ağlar daha çok uygulanmaktadır. Bu ağların birçok farklı yapıyla oluşturulabilmesinden dolayı tek model yapısında uzmanlaşması zordur bu da eğitim algoritmalarının tutarsızlığına ve eğitiminin güç olmasına sebep olmaktadır (Zhang, 2003).




Şekil 4.6. Geri beslemeli yapay sinir ağı isleyişi (Güven, 2020)

Şekil 4.6’da görüldüğü üzere geri beslemeli ağlarda hücrenin çıkışı, başka bir hücreye ya da kendisine girdi olarak verilmektedir. Geri beslemeli ağlar katmandaki hücreler arasında veya katmanlar arasında da olabilir. Bu da ağın yapısının doğrusal olmayan bir yapıya sahip olduğunu gösterir.

- **Geri Beslemeli Geri Yayılımlı Sinir Ağları (Feed Forward, Back Propagation Networks)**

Geri beslemeli geri yayılımlı ağlar YSA ’da sıkça kullanılan modellerdir. Bu ağlarda işlemciler katmanlar halindedir ve sadece bitişik katmanlardaki elemanlar iletişim halindedir. Geri beslemeli geri yayılımlı ağlarda bilgi akışı geriye doğrudur. Bu nedenler ağıdaki hatalar geriye doğru yayılarak öğrenilir.



Şekil 4.7. Geri Beslemeli Geri Yayılımlı Sinir Ağı Modeli Mimarisi (Rajpal vd., 2006)

4.1.6. Yapay Sinir Ağlarında Öğrenme Kuralları

YSA'nın öğrenme yeteneği en önemli özelliklerinin başında gelir. Öğrenme, ağın başlangıçta rastgele atanan ağırlıkların belirlenmesidir. Yapay sinir ağı her bir örnek için ağırlık değerlerini değiştirir. Bu işlem, ağ genelleme yapabilecek duruma gelene kadar devam eder (Yücesoy, 2011). Ağırlık değerlerinin değiştirilmesi, öğrenme kurallarına göre yürütülür (Efe ve Kaynak, 2000).

Yapay sinir ağlarının öğrenme süreci insanlar ile benzerdir. İnsan beyni doğumdan itibaren sürekli gelişir ve olaylar karşısında tecrübe kazanır, ancak yeni bir olayla karşılaştığında yine tecrübesizdir. Yapay sinir ağları da tipik insan beyni gibi dışarıdan gelen girişleri beynin merkezine iletip aktivasyon fonksiyonundan geçirerek bir çıkış üretir. YSA ağırlıklarını yenileyerek ve çeşitli öğrenme algoritmaları kullanarak hataları minimize edip gerçek değerlere yaklaşmaya çalışır. Bu ağırlıklara istenilen sonuca ulaşılan kadar yenilenir ve buna öğrenme denir. Öğrenme gerçekleşikten sonra yeni girişler verilir ve ağın çıktısı ile gerçek değerler karşılaştırılır. Genellikle eldeki örneklerin %80'i ağın eğitimi, %20'lik kısım ise ağın davranışını inceleyip, test için kullanılır (Öztemel, 2003).

Yapay Sinir ağlarında öğrenme işlemi, matematiksel olarak ifade edilmesi zor ve karmaşık işlemlerdir. Bu nedenle öğrenme işlemi kolaylaştırmak için farklı öğrenme kuralları geliştirilmiştir. En yaygın olarak kullanılan kurallar aşağıda verildiği gibidir:

- Hebb Öğrenme Kuralı

Bu kural Donald Hebb tarafından geliştirilen ve öğrenme kuralları arasında en çok kullanılan öğrenme kuralıdır. Hebb öğrenme kuralının temel tanımı şöyledir: Bir nöron başka bir nörondan girdi aldığı anda bu iki nöron aynı işarete sahip ise, nöronlar arasındaki ağırlık güçlendirilmelidir (Hebb, 1949). En eski öğrenme kuralı olarak bilinmektedir. Bu kurala göre öğrenme sinyali hücre çıkışına eşittir.

- Hopfield Öğrenme Kuralı

Hopfield kuralı Hebb kuralına benzerdir ancak ilave olarak ağırlıkların güçlendirilmesi ya da zayıflatma için büyüklük tanımlamak gerekmektedir. İstenilen girdi ve çıktıları aktif ya da pasifse, bağlantı ağırlığı öğrenme oranı kadar artırılır, tersi durumda ise azaltılır. Bu kuralın Hebb kuralından farkı yapay sinir ağı elemanlarının bağlantılarının ne derecede güçlendirilmesi veya zayıflatılması gerektiğini belirlemektir. Ağırlıkların

güçlendirilmesi ve ye zayıflatılması, öğrenme katsayısı ile gerçekleşir. Uygulamada öğrenme hızı 0-1 arasında seçilmektedir (Efendigil, 2008).

- Delta Öğrenme Kuralı

Delta kuralı Widrow ve Hoff tarafından geliştirilmiştir. Bu kurala göre hedef ve elde edilen çıktı arasındaki farkı minimize etmek için YSA işlemciler arasındaki bağlantı ağırlıklarını devamlı değiştirilerek yeniden hesaplamalar yapar. Bu kuralda hedef çıktı ile elde edilen çıktının hata karelerinin ortalamasını minimuma indirmek amaçlanmıştır.

- Kohonen Öğrenme Kuralı

Kohonen kuralı, 1982 yılında Kohonen tarafından geliştirilmiştir. Bu kurala göre sinir hücreleri ağırlıkları değiştirmek için birbirleri ile yarışır. En büyük çıktıyı üreten hücre yani ağırlık vektörleri girdi vektörlerine yakın olan kazanan hücre olur ve bağlantı ağırlıklarını değiştirir. Kazanan hücre, yanındaki hücelere göre daha kuvvetli hale gelmektedir (Öztemel, 2003).

4.1.7. Yapay Sinir Ağlarının Avantajları ve Dezavantajları

Avantajları: YSA modeli diğer sistemlerle kıyas edildiğinde birçok üstün özellikleri sayılabilir. Bu avantajlardan bazıları aşağıdaki gibidir:

- Örneklerden öğrenme yeteneği sayesinde girdi verilerini kullanarak çıktı verilerinin tahmininde bulunması, hata ayıklama özelliği, hesapları çok hızlı yapabilmesi, hazır paketlerinin bulunması sayesinde tasarım kolaylığı sağlar.
- Değişken sayısı sınırsız dahi olsa sadece gerektiği kadarını kullanarak en doğru sonuca ulaşması ve bu değişkenleri veri saklama özelliğiyle saklayıp veri güvenliği sağlar.
- Geleneksel istatistik yöntemleriyle çözülemeyen birçok karmaşık problemleri hızlı bir şekilde çözerek zaman kazandırması. Bu işlemleri yaparken herhangi bir denklem içermediğinden nasıl yaptığı da bilinmez. Bu yüzden bu model bazı insanlar tarafından ‘kara kutu’ olarak adlandırılmaktadır.
- Esnek bir yapıya sahip olmasından dolayı YSA, çok sayıda işlemciden oluşur ve bağlantılarının ağırlıkları ayarlanabilir.

- Veri giriři ne kadar çok artarsa dođru orantılı olarak YSA modelinin verdiđi sonuçların dođruluđu da artmaktadır.

Dezavantajları: Yapay sinir ađlarının bahsedilen avantajlarının yanında dezavantajlarından bahsetmek mümkündür. Bunlardan bazıları ise ařađıdaki gibidir:

- Bir problem ile karřılařıldığında buna çözüm üretildikten sonra bu çözümün nasıl üretildiđinin bulunamaması bir dezavantaj olarak sayılabilir. Ađın davranıřlarının açıklanamaması ađın ürettiđi çözümlere güveni de azaltmaktadır.
- Ađı çalıřtırmak için eđitmek gereklidir fakat eđitimin ne zaman bitirileceđinin kararını vermeye yönelik herhangi bir yöntemin bulunmaması bu modelin bir dezavantajıdır. Hata oranının belirli bir deđer altında olduđunda eđitimin tamamlandıđı kabul edilmektedir.
- Bir diđer dezavantaj ise ađın sadece nümerik deđerler ile çalıřmasıdır. Ađ nümerik deđerler ile çalıřtıđından tüm verileri nümerik formata çevirmek gerekir. Bu formata çevirirken oluşabilecek karıřıklıklar sonucu olumsuz etkileyebilmektedir.
- Verilerin sayısı ne kadar yüksek olursa o kadar ađın performansı yüksek olmaktadır. Fakat az sayıda bir veri ile çalıřılması gerekiyorsa ađdan beklenen performansta düşük olmaktadır.
- En iyi performansı elde etmek için ađ yapısının da belirlenmesi gerekmektedir. Ađ yapısını belirlemek için bir yöntem bulunamadıđından dođru ađrı yapısını belirlemek oldukça zordur. Böyle bir durumda deneme yanılma yöntemi kullanılarak en iyi ađ yapısı belirlenebilir.

Yukarıda belirtilen avantajlar ve dezavantajlar göz önünde tutulduđunda yapay sinir ađlarının çok karıřık problemleri çözmesindeki üstün performansı ve birçok alanda gösterdiđi başarılı sonuçları modelin dezavantajları olmasına rađmen modele duyulan ilgiyi ve güveni azaltmamıřtır.

4.2. Destek Vektör Makineleri (DVM)

DVM, Vapnik tarafından 1992'de sınıflandırma problemleri için ortaya çıkmıřtır. DVM yöntemi, istatistiksel teorileri kullanan ve dođrusal olmayan problemlerin çözümünde kullanılan bir makine öğrenme tekniđidir.

Bu yöntemin makine öğrenmedeki diğer yöntemlerden farkı yapısal riskin minimizasyonuna odaklanmasıdır. DVM, doğrusal olmayan girdileri Kernel fonksiyonu kullanarak doğrusal bir girdiye dönüşmektedir. Bundan dolayı doğrusal olmayan regresyon problemlerinde iyi sonuçlar vermeleri beklenmektedir (Yakut, 2014). DVM yönteminin; sınıflandırma, karakter tanıma, zaman serileri ve regresyon gibi kullanım alanları mevcuttur.

Destek Vektör makineleri yaklaşımının temel avantajları ve dezavantajları şunlardır (Elmas, 2012):

Avantajları;

- Tahmin doğruluğu oldukça yüksektir.
- Genelleme yeteneği yüksektir.
- Karmaşık problemleri modelleyebilme yeteneğine sahiptir.
- Hem doğrusal hem de doğrusal olarak ayrılamayan verilere uygulanabilmektedir.
- Çok sayıda bağımsız değişkenle çalışabilmektedir.

Dezavantajları;

- Eğitim ve test verilerinin boyutlarının yükselmesi hızını azaltmaktadır.
- En büyük sınırlaması çekirdek seçimidir.

4.2.1. Destek Vektör Makineleri Sınıflandırması

DVM, veriler üzerinde genellemeler yaparak sınıflandırma yapabilmektedirler. Sınıflandırma yaparken girdiler, yani eğitim verileri bir hedef değer ve örneğin özelliklerini içermektedirler. DVM bu özelliğe göre hedef değeri tahminlemeye ve sınıflandırma hatalarını en aza indirmeye çalışır (Güven, 2020).

4.2.1.1. Maksimum Marj Destek Vektör Makineleri (Doğrusal Ayrılabilir Durum)

DVM'lerin ilk olarak tanıtılan ve en basit yöntemi olarak bilinen modeli maksimum marj sınıflandırıcıdır.

$$\theta = \{x_i, y_i\}, i = 1, 2, \dots, N$$

$y_i \in \{-1, 1\}$ hedef değeri ve $x_i \in R^d$ ise özellik vektörü olarak ifade edilir.

Burada amaç, eğitim hatasını en aza indirmek ve eğitim girdilerini doğru şekilde ayıran bütün hiperdüzlemler arasında maksimum marja sahip olanı bulmaktır. Bir hiperdüzlem tanım olarak boyutları birbirinden ayıran ayırıcılardır diyebiliriz. Bu ayırıcılar iki boyut olduğunda bir doğru iken üç boyut olduğunda bir düzlem olmaktadır.

Burada öğrenme gerçekleşirken karar fonksiyonuna $d(x,w,b)$ parametreleri hesaplanır (Tolun, 2008).

$$d(x,w,b) = w^T x + b = \sum^n w x + b \quad (4.3)$$


$$y_i(w \cdot x_i + b) \geq 1 \quad (4.4)$$

$$w \cdot x + b = 0 \quad (4.5)$$

x ; hiperdüzlemde bir nokta

w ; ağırlık vektörünü

b : bias (eşik değer)



Şekil 4.8. Maksimum marj hiperdüzlem (Kavzoglu ve Çölkesen, 2009)

Destek vektör makinelerinde amaçlanan bu iki sınıfı ayıran en uygun hiperdüzlem mesafesini bulmak yani aradaki sınırı maksimum yapmak amaçlanmaktadır. Optimum hiperdüzlemin bulunabilmesi için $\|w\|$ 'nin minimum olması gerekmektedir. Bunu yaparken Lagrange çarpanları yöntemi kullanılarak problem çözülür.

$$w = \sum_{i=1} \alpha_i y_i x_i \quad \alpha_i \geq 0, \quad (4.6)$$


$$\alpha_i [y_i (w \cdot x_i + b) - 1] = 0, \quad i=1, \dots, l \quad (4.7)$$

$$L(\alpha) = \sum \alpha_i - \sum \sum \alpha_i \alpha_j y_i y_j (x_i x_j) \quad (4.8)$$

denklemleri çözülerek bulunan değer eşitlik 4.6 da yerine konular. Elde edilen denklemler eşitlik 4.7 de yerine konularak en uygun hiperdüzlem bulunmuş olur.

4.2.1.2. Yumuşak Marj Destek Vektör Makineleri

DVM'lerde maksimum marj sınıflandırma yapılırken öğrenme algoritması doğrusal olarak ayıran veriler için kullanılmaktadır. Bu da gerçek problemlerde yeteri kadar iyi sonuçlar vermemektedir (Güven, 2020). Yani verilerin birbirinden ayrılabilir olması gerekmektedir. Bu yöntem ise veriler doğrusal olarak ayrılamadığı durumlar için kullanılmaktadır. Ayrıca veriyi 0 hata ile ayıklamaktansa benzer özelliklere sahip verileri ayırıcı hiperdüzlemin aynı tarafında bırakacak bir fonksiyon üretmek hedeflenmektedir. Sınıflandırma ile marj arasındaki ilişki denkleme sabit bir sayı eklenerek ayarlanmaktadır.



Şekil 4.9. Doğrusal ayrılmayan değişkenler (Smola ve Schölkopf, 2004)

Burada, ξ_i gevsek değişkenlerdir. ξ_i , bir örneğin kendi sınıfından sapma miktarıdır. Bir önceki bölümde sınıflar arasındaki mesafe maksimum yapılmaya çalışılmıştır. Burada ise örneklerden bazıları hiperdüzlemin içerisinde bulunurken bazıları hiperdüzlemden yanlış tarafa sapmaktadır.

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i, \quad (4.9)$$

$$\xi_i \geq 0$$

Burada eğer $1 > \xi_i$ ise örnek hiperdüzlemin içindedir.

$1 < \xi_i$ ise örnek yanlış ayrılmıştır.

$\xi_i > 0$ olduğunda kendi sınıfının tersi yönde ayrılmıştır.

$$L(\alpha) = \sum \alpha_i - 1/2 \sum \sum \alpha_i \alpha_j y_i y_j (x_i x_j) \quad (4.10)$$

Eşitliğinde en büyük $\alpha \neq 0$ yapan değer için hiperdüzlem hesaplanır.

4.2.2. Destek Vektör Regresyon

Regresyon gerçek değerli bir fonksiyonun sonlu bir gürültülü örnek küme üzerinde tahmin edilmesidir. Regresyonun çıktısı gerçek değerlerin bulunduğu kümeye aittir.

X: Veri kümesi

S: Örnek küme

Hedef Fonksiyon $f: X \rightarrow \mathbb{R}$

D: Eğitim Seti, $D = \{(x, y) \mid x \in S \text{ ve } y = f(x)\}$

$S \subset X$, $f^*: X \rightarrow \mathbb{R}$ D de kullanılıyor.

$$f^*(x) \cong f(x) \quad (4.11)$$

Makine öğrenmenin en önemli hedefi; risk minimizasyonunu sağlayarak tüm verilerin evreninde X üzerinde hedef fonksiyon çıkışını mümkün olduğu kadar en iyi elde etmesidir (HAMEL, 2009). Destek Vektör Regresyonu için, iki tür yapısal risk bulunmaktadır. Bunlardan ilki karmaşıklık terimi, diğeri fonksiyonun ampirik riskidir. Eşitlikler aşağıdaki gibi ifade edilmiştir.

$$R = CR [f] + \|w\|^2 = C \sum |y - f(x)| + \|w\|^2 \quad (4.12)$$

$x_i \in \mathbb{R}$, $y_i \in \mathbb{R}$, $w \in \mathbb{R}$

$R_{\text{amp}}[f]$ eğitim hatası

Y_i gözlenen değerler ve ($f(x)$) tahminden elde edilen veriler arasındaki hataların toplamına kayıp fonksiyon denir (Elmas, 2012). DVM'lerin regresyon problemlerine uyarlanabilmeleri için modele kayıp fonksiyon eklenmektedir. Yapısal risk minimizasyonunu belirlemek için w parametresinin minimizasyon denklemi tarafından minimize edilmesi gerekir.

$$R[\lambda] = \int l(y, f(x, \lambda)) P(x, y) dx dy \quad (4.13)$$


DVM'lerde regresyon performansını etkileyen 3 parametre bulunmaktadır. Bunlar; düzenleme faktörü (C), hata terimi (ϵ) ve kernel denklemleridir.

Düzenleme Faktörü (C)

Burada marjı maksimize, eğitim hatasını ise minimize etmek için C parametresi kullanılır. C' nin 0' a yaklaşık olması modelin daha az karmaşık olacağını göstermektedir. C' nin sonsuza gitmesi ise regresyonun bir hataya izin vermemesine ve modelin karmaşık olmasına sebep olacaktır.

Hata Terimi (ϵ)

Hata terimi (ϵ), destek vektör makinelerinde modelin performansını kontrol eder. Hata teriminin küçük olması tahminin sonucunun uyumlu olduğunu, büyük olması ise tahmin sonucunun uyumunun düşük olduğunu gösterir.



Şekil 4.10. ϵ -duyarsız kayıp fonksiyon (Moura vd., 2011)

Şekil 4.10'da sağ taraftaki fonksiyon duyarsız kayıp fonksiyonu, sol tarafta ise bir veri kümesindeki doğrusal DVM gösterilmektedir.

Kernel (Çekirdek) Denklemleri

Kernel fonksiyon, DVM' lerin doğruluğunda ve hesaplamadaki hızlarında önemli bir parametredir. Bu fonksiyonun matematiksel gösterimi eşitlik 4.14'de verildiği gibidir.


$$K(x_i, x_j) = \phi(x) \cdot \phi(x_j) \quad (4.14)$$

Çoğunlukla kullanılan kernel fonksiyonları; Polinom kernel, Radyal tabanlı kernel, PUK kernel ve Normalleştirilmiş polinom kerneli fonksiyonlarıdır. Bu fonksiyonların matematiksel gösterimi ve parametreleri, diğer bölümde çizelge 4.4'te anlatılmıştır.

Destek vektör makineleri kernel fonksiyonunun desteği ile doğrusal olmayan dönüşümler gerçekleştirerek verilerin doğrusal olarak ayrılmasını sağlamaktadır.

4.2.3. Doğrusal Olmayan Destek Vektör Regresyon

DVM, doğrusal olmayan verilere uyum sağlama konusunda oldukça başarılıdır. Eğitim verilerini anlayabilmek için doğrusal olmayan özellik uzayı oluşturur $\Phi(x^{\vec{}})$. Doğrusal olmayan DVM gözlem vektörünü başka vektöre dönüştürerek yeni doğrusal sınıflandırıcı elde etmek ister (Yakut, 2014). Yüksek dereceli uzayın oluşması boyutların artırılmasına bağlıdır. Böylelikle yeterli sayıya sahip boyutlar ile veri doğrusalmış gibi davranır.



Şekil 4.11. Doğrusal ayrılmayan verilerin doğrusal ayrılabilir hale gelmesi (Güven, 2020)

Gerçekte veri kümeleri doğrusal değildir. Böyle olduğu zamanlarda bazı dönüşüm fonksiyonları tercih edilmektedir. Kernel fonksiyonları, doğrusal olmayan destek vektör makinelerinde karar vermede büyük öneme sahiptir.

$$K: R^d \times R^d \rightarrow R: K(x_1, x_2) = \Phi(x_1)^T \Phi(x_2) \quad (4.15)$$

Yani DVM'lerde doğrusal olmayan veri kümelerine kernel fonksiyonları uygulanarak doğrusal bir fonksiyona dönüştürülmesi sağlanır. DVM regresyon (doğrusal olmayan) fonksiyonu eşitlik 4.16'da verildiği gibidir.

$$f(x) = \sum (\alpha - \alpha^*) K(x, x_i) + b \quad (4.16)$$

Çizelge 4.4. Bazı Kernel Fonksiyonları (Kavzoglu ve Çölkesen, 2009)

Kernel fonksiyonu	Matematiksel ifadesi	Parametre
Polinom Kerneli	$K(x, y) = ((x \cdot y) + 1)^d$	Polinom derecesi (d)
Normalleştirilmiş Polinom Kerneli	$K(x, y) = \frac{((x \cdot y) + 1)^d}{\sqrt{((x \cdot x) + 1)^d((y \cdot y) + 1)^d}}$	Polinom derecesi (d)
Radyal Tabanlı Fonksiyon Kerneli	$K(x, y) = e^{-\gamma\ x-x_i\ ^2}$	Kernel boyutu (γ)
Pearson VII (PUK) Kerneli	$\frac{1}{\left[1 + \frac{2\sqrt{\ x - y\ ^2 \sqrt{2^{(1/\omega)} - 1}}}{\sigma} \right]^{2\omega}}$	Pearson genişliği parametreleri (σ, ω)

Literatürde en sık kullanılan kernel fonksiyonları çizelge 4.4'te parametreleri ve formülleri ile birlikte gösterilmiştir. Çizelgede görüldüğü üzere bütün kernel fonksiyonları için bazı parametrelerin kullanıcı tarafından belirlenmesi gerekmektedir. Burada fonksiyonlar için d, polinom kuvvetini ifade etmektedir. Fonksiyonlar karşılaştırıldığında radyal tabanlı ve polinom kernel fonksiyonlarının daha sade olduğu görülmektedir. Burada polinom derecesindeki artış algoritmanın karmaşık bir hal almasına sebep olmakta ve işlem süresini uzatmaktadır. Puk kernel fonksiyonu pearson genişliği olarak adlandırılan iki parametresi bulunmaktadır ve diğer fonksiyonlara göre daha karmaşık bir yapıya sahiptir. Hangi parametrenin daha iyi sonuç vereceği önceden bilinmediği için en uygun parametrenin belirlenmesi modelin performansı için önemlidir.

Ayrıca kernel fonksiyonlarının özel parametrelerinin dışında düzenleme parametresi C kullanıcı tarafından belirlenmelidir. C, çok küçük ya da çok büyük değer aldığı anda optimum hiperdüzlem doğru belirlenemeyeceği için modelin doğruluğunda düşüş beklenir.

Ayrıca $C = \infty$ olduğunda model sadece doğrusal ayrılabilen veriler için uygulanır hale gelmektedir (Kavzoglu ve Colkesen, 2009). Buradan da anlaşılacağı üzere parametrelerin uygun değerlerinin seçimi modelin DVM performansını önemli derecede etkilemektedir.

5. YAPAY SİNİR AĞLARI VE DESTEK VEKTÖR UYGULAMASI

5.1. Firma ve Ürün Bilgisi

Milattan önceki zamana kadar dayanan un değirmenciliği günümüzde hala yerini korumakta ve gün geçtikçe talebi artarak değirmen endüstrisine olan ihtiyacı ortaya çıkarmaktadır. Bu çalışma değirmen makineleri endüstrisinde faaliyet gösteren bir firmada gerçekleştirilmiştir. Firma bu sektörde 20 yılı aşkın süredir bulunmakta ve hem yurtiçi hem de yurtdışı müşteri profili ile sektörde önemli bir konumdadır.

İşletme hem yurtiçi hem de yurtdışı müşterileri için un ve yem fabrikalarının komple imalatı ve kurulumunu aynı zamanda da ayrı ayrı değirmen makinelerinin üretimini ve satışını gerçekleştirmektedir. Firmanın ürün grupları şu şekildedir;

- Temizleme ve Tavlama Makineleri
- Öğütme Makineleri
- Paketleme Makineleri
- Taşıma Makineleri
- Depolama Ürün Grubu
- Yedek Parça

Bu tez kapsamında temizleme ve tavlama ürün grubunda bulunan 11 adet makinenin 2012-2022 yılları arasındaki satış verileri kullanılarak gelecek yıllar için satış tahmin çalışması yapılmıştır. Çalışmada, yapay zekâ tekniklerinden destek vektör regresyon ve yapay sinir ağları yöntemleri kullanılarak elde edilen sonuçlar karşılaştırılmıştır.

5.2. Problemin Tanımlanması ve Veri Setinin Oluşturulması

Bu tez kapsamında değirmen makineleri imalatı yapan ve komple değirmen kurulumu üstlenen bir firmanın temizleme ve tavlama makineleri ürün grubunun satışını etkileyen değişkenler belirlenerek bu makinelere ait gelecek dönem için satış

tahminleri gerçekleştirilecektir. Fabrika içinde konu ile uzman kişilerle görüşülerek bu ürün grubunun satışını etkileyen değişkenler aşağıdaki gibi belirlenmiştir.

- Dünyada üretilen buğday adetleri
- Dünya nüfusu
- Dolar kuru

Uygulamada bağımlı değişken olarak temizleme ve tavlama grubu makinelerinin aylık satış adetleri alınacaktır. Firmada veriler Microsoft Excel programı üzerinden tutulmakta ve takibi yapılmaktadır. Bu ürün grubuna ait 2012-2022 yılları arasındaki 11 yıllık toplam 132 adet veri kullanılmıştır.

1. Aylık Satış Verileri


Excel üzerinden alınan temizleme ve tavlama grubuna ait 11 adet makinenin aylık satış verileri aşağıdaki gibidir:

Çizelge 5.1. Aylık satış verileri

T-T ürün grubu	Ocak	Subat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2012	161	141	152	180	165	134	103	123	187	210	178	169
2013	130	180	195	187	173	116	127	130	164	200	210	178
2014	146	163	173	155	199	127	139	119	249	219	236	245
2015	193	252	234	271	267	153	183	191	260	292	301	363
2016	254	375	313	258	196	101	98	184	295	299	350	387
2017	295	300	303	257	210	167	198	145	308	382	350	325
2018	452	413	414	400	401	250	275	334	479	501	542	567
2019	430	426	428	412	411	313	376	395	531	519	491	480
2020	456	461	353	380	361	371	357	355	454	448	171	170
2021	125	130	140	145	150	160	165	170	177	200	380	450
2022	400	395	390	393	395	390	385	376	405	407	410	415

2. Dünyada Üretilen Buğday Miktarı

Değirmen endüstrisinin ana ürünü olan unun hammaddesi tahıllardır. Bu tez kapsamında dünyada üretilen buğday miktarları alınmıştır.



Şekil 5.1. Dünyada üretilen buğday miktarları (Statista, n.d)

Yukarıdaki şekilde 2012-2022 yıllarına ait dünyada üretilen buğday miktarına ait grafiği görmekteyiz. Üretilen buğday adetleri milyon metrik ton biriminde ifade edilmektedir

Çizelge 5.2. Buğday adetleri

Yıl	Dünyada üretilen buğday adetleri (milyon metrik ton)
2012	697
2013	655
2014	717
2015	728,3
2016	735,9
2017	756,5
2018	761,5
2019	731,4
2020	762,2
2021	774,9
2022	778,6

Çizelge 5.2 'de görüldüğü üzere buğday adetleri ile ilgili elde ettiğimiz veriler yıllık verilerdir. Gerekli araştırmalar yapılmış ancak aylık verilere ulaşılamamıştır. Bu nedenle aylık satış verileri üzerinden yüzde oranları hesaplanmıştır. Bu hesaplanan

aylık yüzde oranlarına ile yıllık buğday üretim adetleri çarpılarak yıllık veriler aylığa dönüştürülmüştür. Bahsedilen işlemler aşağıdaki gibidir:

$$(AS*100) / YTS = YO \quad (5.1)$$

Burada;

AS: satış miktarı (aylık)

YTS: toplam talep adedi (yıllık)


YO: yüzde oranı

Çizelge 5.3. Aylık buğday üretim adetleri

Buğday adt.	Ocak	Subat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2012	58968	51643	55672	65927	60434	49079	37725	45050	68491	76915	65195	61899
2013	42789	59246	64183	61550	56942	38181	41802	42789	53980	65829	69121	58588
2014	48241	53858	57162	51214	65753	41963	45928	39319	82273	72361	77978	80952
2015	47487	62004	57575	66679	65695	37645	45027	46995	63972	71846	74060	89315
2016	60102	88734	74063	61049	46378	23899	23189	43539	69804	70751	82818	91573
2017	68879	70046	70747	60006	49032	38992	46231	33856	71914	89192	81721	75883
2018	68460	62553	62704	60584	60735	37865	41651	50588	72549	75881	82091	85878
2019	60343	59781	60062	57817	57676	43924	52765	55431	74516	72832	68903	67359
2020	80139	81018	62037	66783	63443	65201	62740	62389	79788	78733	30052	29876
2021	40493	42113	45352	46972	48591	51831	53450	55070	57338	64788	123098	145774
2022	65415	64597	63779	64270	64597	63779	62962	61490	66233	66560	67050	67868

3. Dünya Nüfusu

Değirmen makineleri, temel besin kaynaklarının hammaddesini işleyen teknolojiler olmasından kaynaklı nüfusun artması bu besinlere olan ihtiyacı doğrudan etkilemektedir. Bu nedenle dünya nüfusunun değirmen makineleri talebinde bir değişken olabileceği düşünülmüştür. Araştırılan farklı kaynaklar sonucunda elde edilen nüfus bilgileri aşağıdaki gibidir:



Şekil 5.2. Dünya nüfus verileri (Statista, n.d)

Dünya nüfusu verilerinin yıllık olması sebebiyle bu veriler öncelikli olarak aylık verilere dönüştürülecektir. Bunun için birleşik faiz oranına göre eşdeğer faiz oranı formülünden yararlanılmıştır.

Yıllık nüfus artış oranına göre aylık nüfus artış oranı hesaplaması eşitlik 5.2'deki formulizasyona göre yapılmıştır.

$$i_{aylik} = \sqrt[12]{1 + i_{yil}} - 1 \quad (5.2)$$

i = hesaplanan yıl

İlk olarak, çizelge 5.4'te verilen yıllık nüfus artış oranları eşitlik 5.2 ye göre hesaplanarak aylık nüfus artış oranları belirlenmiştir.

Çizelge 5.4. Dünya nüfusu verileri

	Dünya nüfusu(milyar)	Artis oranı(%)	Yıllık artis oranı	Aylık artış oranı
2011	7073125425	1,25	0,0125	0,001035746
2012	7161697921	1,25	0,0125	0,001035746
2013	7250593370	1,24	0,0124	0,001027507
2014	7339013419	1,22	0,0122	0,001011026
2015	7426597537	1,19	0,0119	0,000986299
2016	7513474238	1,17	0,0117	0,00096981
2017	7599822404	1,15	0,0115	0,000953319
2018	7683789828	1,1	0,011	0,000912077
2019	7764951032	1,06	0,0106	0,000879071
2020	7840952880	0,98	0,0098	0,000813021
2021	7909295151	0,87	0,0087	0,000722125
2022	7975105156	0,83	0,0083	0,000689049

Örnek vermek gerekirse 2013 yılının ocak ayı için nüfus verisi hesaplanırken öncelikle eşitlik 5.2'deki formüle göre yıllık artış oranından aylık artış oranı hesaplanır. Daha sonra 2012 yılının yıllık nüfus verisi ile bu hesaplanan aylık artış oranı çarpılarak 2013 yılının ilk ayının nüfus verisi hesaplanır. Devam eden yıllar içinde yine o yılın aylık artış oranı ile bir önceki ayın nüfus verileri çarpılır. Bütün aylar için bu işlemler tekrarlanır. Bu sonucuna göre; 2012-2022 yılları için hesaplanan aylık nüfus verileri aşağıdaki çizelge 5.5 'te sunulduğu gibidir.

Çizelge 5.5. Aylık Dünya Nüfusu Verileri

	2012	2013	2014	2015	2016	2017	2018	2019	2020	2021	2022
Ocak	7080451386	7169056613	7257923906	7346251879	7433799928	7520636975	7606754030	7690544422	7771264102	7846615028	7914745045
Şubat	7087784936	7176422867	7265261854	7353497477	7441009304	7527806541	7613691978	7697304954	7777582305	7852281265	7920198695
Mart	7095126081	7183796689	7272607221	7360750222	7448225671	7534982941	7620636254	7704071429	7783905645	7857951594	7925656103
Nisan	7102474829	7191178088	7279960014	7368010121	7455449037	7542166183	7627586864	7710843852	7790234126	7863626018	7931117271
Mayıs	7109831189	7198567071	7287320241	7375277180	7462679409	7549356273	7634543813	7717622228	7796567752	7869304539	7936582202
Haziran	7117195169	7205963647	7294687909	7382551406	7469916792	7556553217	7641507108	7724406563	7802906528	7874987161	7942050898
Temmuz	7124566775	7213367823	7302063026	7389832807	7477161195	7563757022	7648476753	7731196863	7809250457	7880673886	7947523363
Ağustos	7131946017	7220779606	7309445600	7397121390	7484412623	7570967695	7655452756	7737993131	7815599544	7886364718	7952999598
Eylül	7139332901	7228199005	7316835637	7404417161	7491671083	7578185241	7662435121	7744795373	7821953792	7892059659	7958479607
Ekim	7146727437	7235626028	7324233146	7411720129	7498936583	7585409669	7669423855	7751603596	7828313207	7897758713	7963963392
Kasım	7154129632	7243060682	7331638134	7419030299	7506209129	7592640983	7676418963	7758417803	7834677792	7903461882	7969450956
Aralık	7161539493	7250502975	7339050609	7426347679	7513488728	7599879192	7683420450	7765238000	7841047552	7909169170	7974942301

FARK 162855,2467
HATA ORANI 0,002042045
0,20%

Bu yöntem kullanılarak yapılan hesaplamalar sonucunda hata oranı %0,2'dir. Yapılan işlemlerin bize yaklaşık doğru nüfus verilerini verdiği düşünülmektedir.

4. Dolar Kuru

İhracat yapılan her işletme döviz kullanmaktadır. Dolar kuru, Türk lirasına karşı bir Amerikan dolarının değerini belirlemektedir. Firmaların hem ürünlerini satışlarında hem de üretim için kullanılacak yurtdışı hammadde yarı mamul alımlarında dolar kuru önemlidir.

Dolar kuru verileri hesaplanırken 2012-2022 yıllarına ait aylık dolar kuru alış ve satışlarının ortalaması alınmıştır.

Çizelge 5.6. Aylık dolar kuru

(alis+satis)/2	Ocak	Subat	Mart	Nisan	Mayıs	Haziran	Temmuz	Ağustos	Eylül	Ekim	Kasım	Aralık
2012	1,84	1,76	1,78	1,78	1,80	1,82	1,81	1,79	1,80	1,80	1,79	1,78
2013	1,77	1,77	1,81	1,80	1,82	1,90	1,93	1,96	2,02	1,99	2,02	2,06
2014	2,22	2,22	2,22	2,13	2,09	2,12	2,12	2,16	2,21	2,26	2,23	2,29
2015	2,33	2,46	2,59	2,65	2,64	2,70	2,69	2,85	3,01	2,93	2,88	2,92
2016	3,00	2,94	2,89	2,84	2,93	2,92	2,95	2,96	2,96	3,07	3,28	3,49
2017	3,74	3,67	3,67	3,65	3,57	3,52	3,56	3,51	3,47	3,67	3,88	3,85
2018	3,77	3,78	3,88	4,05	4,41	4,63	4,75	5,80	6,34	5,85	5,38	5,30
2019	5,34	5,20	5,35	5,60	5,96	5,81	5,68	5,59	5,81	5,68	5,72	5,75
2020	5,95	5,98	6,23	6,65	7,02	6,81	6,85	6,94	7,35	7,70	8,39	7,85
2021	7,37	7,23	7,31	8,18	8,30	8,51	8,69	8,40	8,30	8,86	9,54	13,36
2022	13,44	13,39	13,91	14,68	14,85	16,44	16,74	17,95	18,21	18,57	18,63	18,65

5.3. Yapay Sinir Ağı Mimarisinin Oluşturulması ve Ağı Eğitilmesi

Bu çalışmada yapay sinir ağları uygulaması için Matlab 2022b programı tercih edilmiştir. Yapay sinir ağlarında en sık kullanılan geri yayılım algoritması kullanılmıştır. Aktivasyon fonksiyonu olarak literatürde de en çok kullanılan ve türevi alınabilen bir fonksiyon olan ‘logsig (Log-Sigmoid Transfer Function) fonksiyonu, eğitim fonksiyonu olarak ‘trainrp (Resilient backpropagation) fonksiyonları seçilmiştir. 2012-2022 yıllarına ait 132 adet verinin 106 adedi eğitim, 26 adet veri test için kullanılmıştır. Ağı mimarisi; giriş katmanı, 2 gizli katman ve çıkış katmanı olmak üzere 3 katmandan oluşmaktadır. İlk katmandaki 10, ikinci katmandaki hücre sayısı 5 seçildiğinde en iyi sonuçlar elde edilmiştir. Ayrıca ağın performansını arttırmak ve toplam hatayı en aza indirmek için öğrenme katsayısı belirlenmelidir. Öğrenme katsayısı ağı çalıştırırken kullanıcı tarafından belirlenmektedir. Bu model için en uygun öğrenme katsayısı 0.70 olarak alınmıştır. En iyi ağ mimarisini belirlemek için yapılan çeşitli denemeler Çizelge 5.7’de gösterilmiştir.

Çizelge 5.7. YSA mimarisi için deneme yanılma sonuçları

Aktivasyon Fonksiyonu	Katmanlardaki Nöron Sayısı	Eğitim Fonksiyonu	Öğrenme Sayısı	MAPE	R ²
purelin	1--1	trainlm	0,50	0,12	0,80
tansig	2--2	trainlm	0,60	0,09	0,88
logsig	4--4	trainbfg	0,70	0,12	0,87
logsig	3--6	trainbfg	0,70	0,10	0,90
logsig	5--10	trainrp	0,70	0,07	0,95
logsig	3--6	trainrp	0,75	0,10	0,91
logsig	5--5	trainrp	0,70	0,15	0,84
logsig	10--5	trainoss	0,75	0,12	0,85
logsig	10--10	trainlm	0,80	0,09	0,79
logsig	15--10	trainrp	0,80	0,08	0,81
logsig	15--15	trainrp	0,90	0,11	0,86

5.4. Yapay Sinir Ağları Tahmin Uygulaması

1.Adım: Veri Setinin MATLAB'a Aktarımı

Talep tahmin çalışmasına başlamak için ilk olarak Microsoft Excel dosyasında bulunan veriler (girdi değişkenleri ve çıktı değişkeni) Matlab'a aktarılmıştır. Ardından veri sayısı bulunarak girdi ve çıktı değişkenlerinin boyutları belirlenir. Daha sonra verilerinin yüzde kaçının eğitim, yüzde kaçının test için kullanılacağı tanımlanır. Bu çalışmada toplam verinin %80'i training yani eğitim, %20'si validation yani test için kullanılmıştır. Training_rate, verilerin yüzde kaçının eğitim için kullanılacağını belirtir ve 0 ile 1 arasında olmalıdır.

```
Command Window
>> veri=xlsread('satisverileri.xlsx');
>> input=veri(:,1:3);
>> target=veri(:,end);
>> noofdata=size(input,1);
>> training_rate=0.80

training_rate =

           0.8

>> ntd=round(noofdata*training_rate);

>> xt=input(1:ntd,:);
>> xv=input(ntd+1:end,:);
>> yt=target(1:ntd);
>> yv=target(ntd+1:end);
>>
```

Şekil 5.3. Verilerin Matlab'a girilmesi

2.Adım: Verilerin Normalize Edilmesi

Matlab'da fonksiyonun çalışması için verilerin sütunlarda olması gerekmektedir. Bu nedenle verilerin transpozu alınarak satırdaki veriler sütunlara dönüştürülür. Verilerin birimlerinin aynı olması için girdi ve çıktı verileri [0-1] ya da [-1-1] arasında normalize edilir. Matlab'da yazılan kodlar aşağıda gösterildiği gibidir.

```
neuralnetwork.m x +
12
13
14     xt=xt';
15     xv=xv';
16     yt=yt';
17     yv=yv';
18
19     xtn=mapminmax(xt);
20     xvn=mapminmax(xv);
21     [lytn, ps]=mapminmax(yt);
22
```

Şekil 5.4. Verilerin normalizasyonu

3.Adım: Yapay Sinir Ağının Oluşturulması ve Parametrelerin Belirlenmesi

Ağı oluştururken öncelikle ağ bilgilerini saklayacak olan değişken belirlenir. Girdiler, çıktılar, gizli katmanlardaki nöron sayısı, transfer fonksiyon ve eğitim algoritması tanımlanır. Girdiler normalize edilmiş eğitim verileridir. Çıktılar ise normalize edilmiş eğitim çıktılarıdır. Daha sonra öğrenme katsayısı (lr) ve ağı ne zaman durulacağını belirlemek için iterasyon sayısı belirlenir. Ayrıca belirli bir yakınsamadan sonra durdurmak için yani max iterasyona gelmeden önce elde ettiğimiz sonuçlar daha fazla değişmiyorsa durdurmak için değişkenler tanımlanır. Devamında sonuçları kaç iterasyonda bir göstereceğini ya da bittiğinde göstereceğini demek için gereken parametreler ile ilgili yazılan kodlar aşağıdaki şekilde gibidir.

```
neuralnetwork.m x +
22
23 net=newff(xtn,ytn,[n1,n2],{'logsig'}, 'trainrp');
24 net.trainParam.lr=lr;
25 net.trainParam.epochs=10000;
26 net.trainParam.goal=1e-10;
27 net.trainParam.show=NAN;
28
```

Şekil 5.5. Ağı oluşturulması

4.Adım: Sinir Ağının Eğitimi

Ağı eğitmek için gereken girdiler; eğittiğimiz ağı adı, eğitim girdisi, eğitim hedefidir. Test girdileri girilip normalize test çıktıları elde edilir.

Test çıktıları denormalize edilerek test ile arasındaki farka bakılır. Yani ağı eğitildi, eğittiğimiz ağı test için veriler sokuldu daha sonra bu veriler denormalize edilerek gerçek aralığına geçirilip elimizdeki veriler ile karşılaştırılması yapılmıştır.

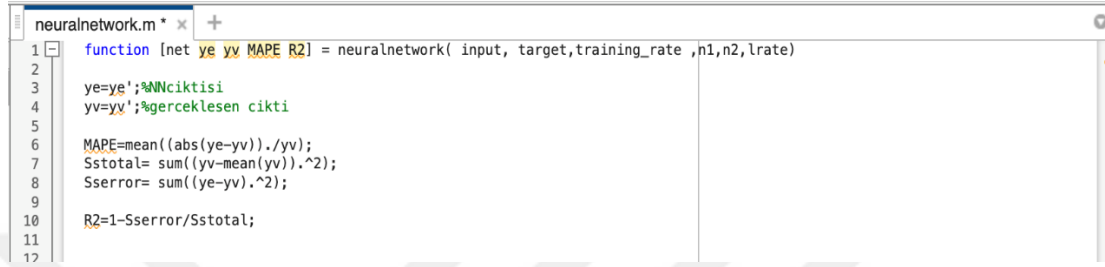
```
neuralnetwork.m x +
28
29 net=train(net,xtn,ytn);
30
31 yen=sim(net,xvn);
32 ye=mapminmax('reverse',yen,ps);
33
```

Şekil 5.6. Ağı eğitilmesi

5.Adım: Sinir Ağı Performans Testi

Bu aşamada ağı eğitimi sonucunda elde edilen değerler ile gerçek değerler arasındaki sapmalara bakılır. Bu sapma ne kadar az ise bize modelin o kadar gerçeğe yakın sonuçlar verdiğini gösterir.

Performans ölçütü olarak ortalama bir veride ne kadar hata verdiği sonucuna bakmak için ortalama mutlak hata yüzdesi (MAPE) hesaplama yöntemi tercih edilmiştir.



```
1 function [net ye yv MAPE R2] = neuralnetwork( input, target, training_rate ,n1,n2,lrate)
2
3 ye=ye';%NNciktisi
4 yv=yv';%gerçeklesen cikti
5
6 MAPE=mean((abs(ye-yv))./yv);
7 Sstotal= sum((yv-mean(yv)).^2);
8 Sserror= sum((ye-yv).^2);
9
10 R2=1-Sserror/Sstotal;
11
12
```

Şekil 5.7. Ağı performans testi

5.4.1. Yapay Sinir Ağı Tahmin Sonuçları

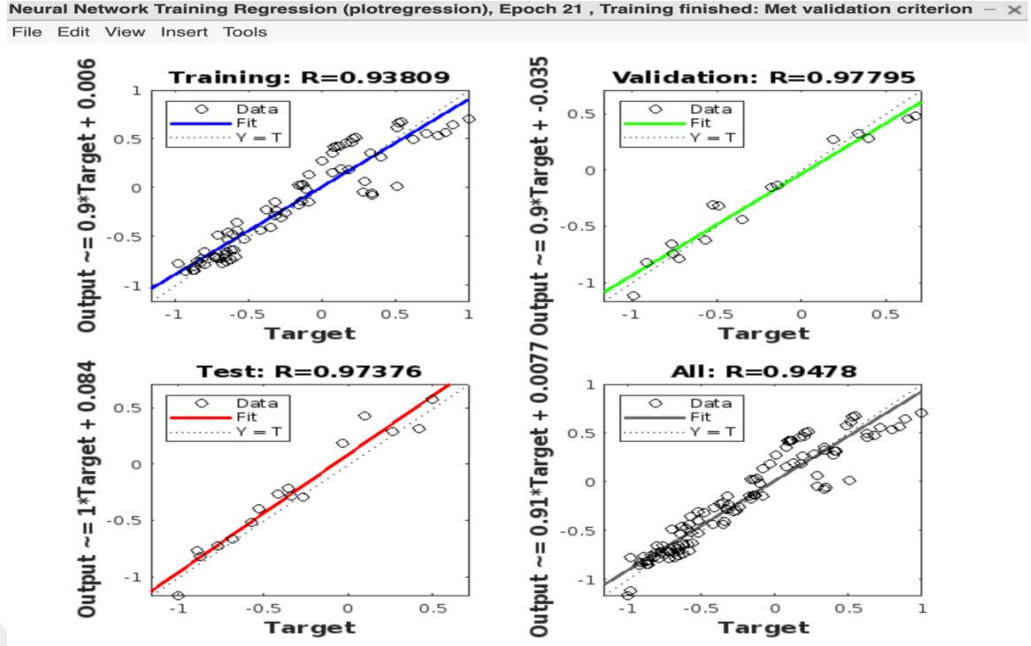
Bu tez kapsamında YSA analizleri için Matlab 2022 b kullanılmıştır. Tahminlerden elde edilen sonuçlara göre; Ortalama Mutlak Hata Yüzdesi (MAPE) 0'a yakın, R^2 ise 1'e yakın değerler alması beklenir. Bu çalışma için MAPE değeri 0.0713 olarak bulunmuştur. Bunun anlamı %7.1' lik bir hata payına sahip olmasıdır. Tahmin edilen varyansın oranı (R^2) ise 0.947 olarak bulunmuştur. Elde edilen bu sonuçlarda parametreler şu şekildedir;

Training_rate= 0.80 alınmıştır. Yani toplam 132 adet verinin %80'i eğitim verisi, %20'si test verisi olarak ayrılmıştır. Katmanlardaki nöron sayıları; n1=10, n2=5, Öğrenme katsayısı: 0.70, Aktivasyon fonksiyonu: logsig. ve Eğitim fonksiyonu: trainrp olarak seçilmiştir.

Bu parametrelere göre ağı bulduğu tahmin değerleri ve gerçekleşen değerler Çizelge 5.8'de gösterilmiştir.

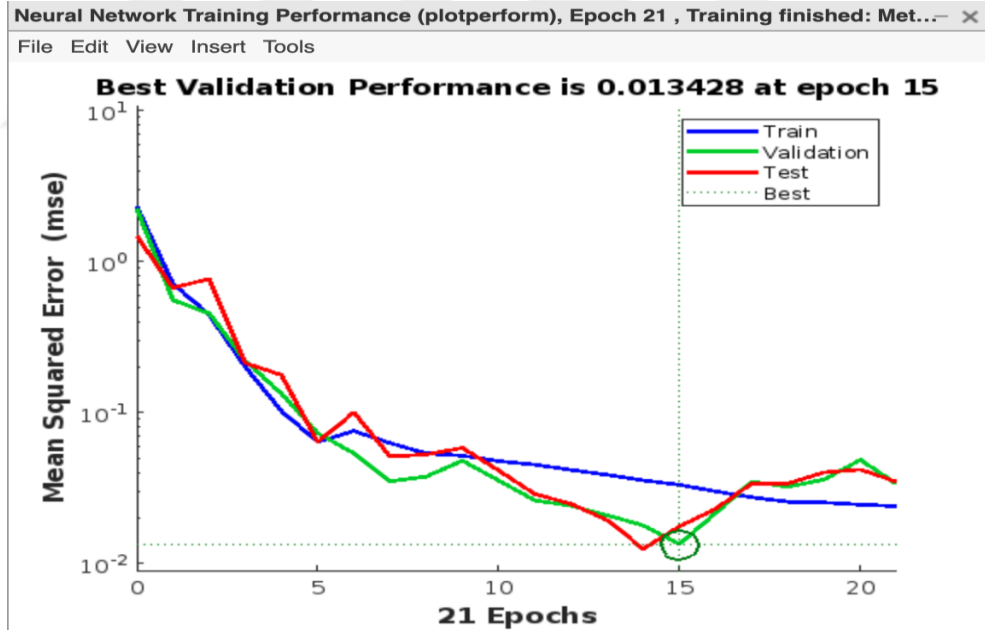
Çizelge 5.8. YSA sonuçları

Gerçek Değerler (yv)	YSA Tahmin Değerleri (ye)	Sapma (adet)	Tahmin Başarısı (%)
171	158	13	%92,40
170	151	19	%88,82
125	134	-9	%92,80
130	131	-1	%99,23
140	130	10	%92,86
145	148	-3	%97,93
150	157	-7	%95,33
160	173	-13	%91,88
165	193	-28	%83,03
170	182	-12	%92,94
177	179	-2	%98,87
200	215	-15	%92,50
380	318	62	%83,68
450	499	-49	%89,11
400	370	30	%92,50
395	361	34	%91,39
390	358	32	%91,79
393	362	31	%92,11
395	360	35	%91,14
390	368	22	%94,36
385	370	15	%96,10
376	364	12	%96,81
405	367	38	%90,62
407	358	49	%87,96
410	348	62	%84,88
415	333	82	%80,24
Ortalama		16	%91,59



Şekil 5.8. Regresyon grafiği

Şekil 5.8’de görüldüğü gibi ağı öğrenmesi başarılı bir şekilde gerçekleşmiştir.

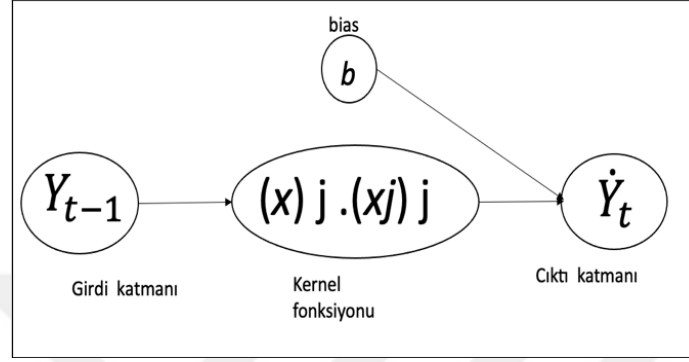


Şekil 5.9. Performans grafiği

Şekil 5.9’da görüldüğü gibi optimum sonuç 21 iterasyonda elde edilmiştir.

5.5. Destek Vektör Makineleri Tahmin Uygulaması

Bu çalışmada Destek Vektör Regresyon uygulaması için Weka 3.9.6 kullanılmıştır. Girdi değişkeni olarak firmanın 2012 ve 2022 yılları arasındaki 132 adet satış verilerininin %80 i olan ilk 106 adet veri kullanılmıştır. Son 26 adet veri ise test için kullanılmıştır. Regresyon modelinin yapısı Şekil 5.10'da görüldüğü gibidir.



Şekil 5.10. DVR model yapısı

En iyi sonuca ulaşmak için çeşitli kernel fonksiyonları denenmiştir. İlk olarak RBF kernel fonksiyonu ile model çalıştırılmıştır. Parametreler; $C= 5.5$ ve $\text{gamma}= 1.7$ olarak çalıştırıldığında modelin en iyi sonuçları verdiği gözlenmiştir. İkinci olarak PUK kernel fonksiyonu seçilmiştir. Parametreler $C=8.5$, $\text{omega}=0.5$, $\text{sigma}=0.7$ olarak seçildiğinde en iyi sonuçlar elde edilmiştir. Son olarak Poly kernel fonksiyonu denenmiştir. Parametreler $C=5.0$ ve $\text{exponent}=2.0$ olarak seçildiğinde en iyi sonuçlar elde edilmiştir. DVR aşırı öğrenmeye duyarlı olduğundan dolayı her bir fonksiyon için 100'e yakın farklı parametre değerleri ile denemeler yapılmıştır.

Ayrıca verilerin yüzde olarak eğitim ve test için ayrıldığı farklı durumlar denenmiş, çeşitli kernel fonksiyonları ile denemeler yapılarak elde edilen sonuçlar çizelge 5.9'de sunulmuştur. En iyi sonuçlar verileri %80 eğitim verisi, %20 test verisi olarak ayrıldığı durumda elde edilmiştir.

Çizelge 5.9. DVM hata sonuçları

Eğitim ve test için kullanılan veri oranları (%)	Kernel fonksiyonları	MAE	RMSE	RAE (%)	RRSE(%)	R ²
Eğitim: %70 Test: %30	RBF Kernel	31,51	55,42	30,74	47,51	87%
	PUK	11,78	20,66	11,49	17,71	97%
	Poly Kernel	31,34	55,12	30,57	47,25	88%
Eğitim: %75 Test: %25	RBF Kernel	28,59	40,34	28,86	35,07	94%
	PUK	13,32	22,42	13,45	19,49	97%
	Poly Kernel	35,8	60,2	36,23	52,4	84%
Eğitim: %80 Test: %20	RBF Kernel	22,78	30,4	21,71	25,5	96%
	PUK	8,78	18,49	8,37	15,51	98%
	Poly Kernel	39,79	65,45	37,92	54,91	84%

Bu denemeler sonucunda elde edilen en iyi sonucun parametreleri şu şekildedir; kernel fonksiyonu PUK, c (düzenleme parametresi) = 8.5, omega=0.5, sigma=0.7 olarak seçilmiştir. Veriler normalize edilmiştir. Elde edilen sonuçlara göre tahmin başarısı %98 'dir. Sonuçlardan elde edilen hata oranları Çizelge 5.9'da gösterildiği gibidir.

6. SONUÇ VE DEĞERLENDİRME

Artan rekabet koşullarında şirketlerin belirsizlikle mücadelelerinde talep tahmini oldukça önemlidir. Bu çalışmada yapay zekâ tabanlı yöntemlerden olan yapay sinir ağları ve destek vektör makineleri kullanılarak değirmen makineleri imalat sektöründe talep tahmin çalışması yapılmıştır. Uygulamada değirmen makineleri imalatı yapan bir firmanın 2012-2022 yıllarına ait temizleme ve tavlama ürün grubu makinelerinin satış adetlerini kullanarak gelecek ayların satış adetleri tahmin edilmeye çalışılmıştır. Satış adetlerini etkileyen değişkenler ise firmanın pazarlama ve satış ekibi ile yapılan görüşmeler sonucunda belirlenmiştir. Çalışmada ilk olarak kullanılacak olan yöntemlerle ilgili detaylı bir literatür taraması yapılmıştır. Edilen bilgiler ile YSA ve DVM uygulaması yapılmış ve bu iki yöntemin sonuçları karşılaştırılmıştır. 2012-2022 yıllarına ait toplam 132 adet satış verisinin %80'i yani 106 aylık veri ağın eğitimi, %20'si yani yaklaşık son 2 yıla ait 26 adet veri ise ağın test edilmesi için incelenmiştir. Tahmin sonuçlarına göre YSA, %95 oranında gerçeğe yakın tahminler yapmıştır. DVM ile yapılan analizlerde üç farklı kernel fonksiyonu denenmiştir. Ayrıca verilerin %70'i eğitim, %30'u test ya da %80'i eğitim, %20'si test verisi olarak ayrıldığında yapılan denemelerin sonuçları sunulmuştur. En iyi sonuç; veriler %80-20 olarak ayrıldığında ve puk kernel fonksiyonu seçildiğinde tahmin başarısı %98 olarak elde edilmiştir. Bu da tahmin edilen değerler ile gerçek değerler arasındaki sapmaların en az puk kernel yöntemi ile hesaplandığını göstermektedir.

Çizelge 6.1. Tahmin başarılarının karşılaştırılması

	YSA	RBF Kernel	PUK Kernel	Poly Kernel
R ²	0,95	0,96	0,98	0,84

Sonuç olarak bu çalışma ile, talebin oldukça dalgalı ve belirsizliğin fazla olduğu değirmen makineleri imalatı yapan firmalar için örnek bir talep tahmin çalışması uygulaması yapılmıştır. Çalışmanın sonuçlarına göre, DVM'den elde edilen sonuçların YSA'ya göre daha başarılı sonuçlar verdiği gösterilmiştir. İleriki çalışmalar için tahmin başarısının daha iyi ölçülmesi için farklı analiz yöntemleri deneyerek DVM ile karşılaştırılabilir.

KAYNAKLAR

Akman, T., Yılmaz, C., & Sönmez, Y. (2018). Elektrik Yükü Tahmin Yöntemlerinin Analizi. *Gazi Mühendislik Bilimleri Dergisi*, 4(3), 168-175.

Adıyaman, F. (2007). Talep Tahmininde Yapay Sinir Ağlarının Kullanılması (*Doctoral Dissertation, Fen Bilimleri Enstitüsü*).

Aydın, D. (2012). Yapay Sinir Ağları Yardımı ile Talep Tahmin Analizi ve Deniz Taşımacılığı Sektöründe Bir Uygulama (*Doctoral Dissertation, Marmara Üniversitesi (Turkey)*).

Aylak, B. L., Okan, O. R. A. L., & Yazıcı, K. (n.d.). Yapay Zekâ ve Makine Öğrenmesi Tekniklerinin Lojistik Sektöründe Kullanımı. *El-Cezeri*, 8(1), 74-93.

Balca, Y. (2007). Düzenli Depolama Alanı Belirlemede Karar Destek Sistemi Kullanımı (*Doctoral Dissertation, Fen Bilimleri Enstitüsü*).

Ballı, M. T. (2014). Yapay Sinir Ağları ile Talep Tahmini ve Gıda Sektöründe Uygulanması.

Bayar, E. (2019). Diferansiyel Polinom Sinir Ağı Tekniği ile Elektrik Tüketim Tahmini (*Master's Thesis, Sakarya Üniversitesi*).

Bilişik, M. T. (2011). "Destek Vektör Makinesi, Çoklu Regresyon ve Doğrusal Olmayan Programlama İle Perakendecilik Sektöründe Gelir Yönetimi İçin Dinamik Fiyatlandırma", *X1. Üretim Araştırmaları Sempozyumu*, 785–799.

Bunjaku, T. R. (2014). PNN ve SVM Kullanarak DWT Tabanlı Yüz Tanıma (*Doctoral Dissertation, Sakarya Üniversitesi (Turkey)*).

Çağlar, T. (2007). Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması (*Master's Thesis, Kırıkkale Üniversitesi*).

Chung, Seunghyun (2001). Demand Modeling And Analysis For The Management Of Underground Infrastructure Systems, *Doktora Tezi, Purdue University, Usa*.

Çoban, F., & Demir, L. (2021). Yapay Sinir Ağları ve Destek Vektör Regresyonu ile Talep Tahmini: Gıda İşletmesinde Bir Uygulama. *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 23(67), 327-338.

Direk, M. (2022). Çin Halk Cumhuriyetinde Tarımsal Üretimin Gelişimi. *Eurasian Journal Of Agricultural Economics (Ejæ)*, 2(1), 41-56.

Durğun, S. (2018). Türkiye'nin Enerji Talebinin Yapay Zekâ Teknikleriyle Uzun Dönem Tahmini (*Doctoral Dissertation, Necmettin Erbakan University (Turkey)*).

Efendigil, T., & Eminler, Ö. E. (2017). Havacılık Sektöründe Talep Tahminin Önemi: Yolcu Talebi Üzerine Bir Tahmin Modeli. *Yaşar Üniversitesi E-Dergisi*, 12, 14-30.

Efe M.Ö., Kaynak O., (2000). Yapay Sinir Ağları ve Uygulamaları, *Boğaziçi Üniversitesi Yayınevi, İstanbul*.

Elmas, M. (2012). Destek Vektör Makineleri ile Fiyat Tahminleri ve Kuyumculuk Sektöründe Bir Uygulama. *İstanbul Üniversitesi*.

Emel, G. G., & Taşkın, Ç. (2002). Genetik Algoritmalar ve Uygulama Alanları. *Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 21(1), 129-152.

Ervural, B. Ç., Sarı, İ. U., & Koçyiğit, B. (2018). Kural Tabanlı Bulanık Yaklaşımla Talep Tahmini ve Hızlı Tüketim Sektöründe Bir Uygulama. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 24(1), 83-93.

Gökçe, H. A. N., Sönmez, E. F., Selen, A. V. C. I., & Aladağ, Z.(2021) Uygun Normalizasyon Tekniği Ve Yapay Sinir Ağları Analizi İle Otomobil Satış Tahminlemesi. *İşletme Ekonomi ve Yönetim Araştırmaları Dergisi*, 5(1), 19-45.

Gürsoy, A. (2012). Yapay Sinir Ağları Yaklaşımıyla Lastik Kalıbı Maliyetinin Tahmin Edilmesi, *Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi*.

Güven, İ. (2020). Perakende Hazır Giyim Endüstrisinde Yapay Zekâ Yöntemleri ile Talep Tahmini.

Hebb, D.O. (1949). The Organization Of Behaviour, A Neuropsychological Theory. John Wiley & Sons Inc, New York.

Hamel, L. (2009). Knowledge Discovery With Support Vector Machines, A John Wiley & Sons , Kanada, 978-0-470-37192-3.

Hyndmanr.J. (2001). Box jenkins modelling. www.personal.buseco.monash.edu.au.

Karaatlı, M., Helvacıoğlu, Ö. C., Ömürbek, N., & Tokgöz, G. (2012). Yapay Sinir Ağları Yöntemi ile Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.

Kavzoglu, T., & Colkesen, I. (2009). A Kernel Functions Analysis For Support Vector Machines For Land Cover Classification. *International Journal Of Applied Earth Observation And Geoinformation*, 11(5), 352-359.

Karahan M. (2011). İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Talep Tahmini Uygulaması. *Doktora Tezi, Selçuk Üniversitesi, Konya, Türkiye*.

Kartalopoulos, S.V. (1996). “Understanding Neural Networks And Fuzzy Logic”, Basic Concepts And Applications, *Ieee Press New York*.

Kölmek, M.A. (2012). Türkiye Elektrik Dengeleme ve Uzlaştırma Piyasasındaki Sistem Gün Öncesi Fiyatların Yapay Sinir Ağları Kullanarak Modellenmesi, *Ankara Üniversitesi, Fen Bilimleri Enstitüsü, Elektronik Mühendisliği Ana Bilim Dalı, Yüksek Lisans Tezi*.

Maltarollo, V. G., Honório, K. M., & Da Silva, A. B. F. (2013). Applications Of Artificial Neural Networks In Chemical Problems. London: Intechopen.

Mehmet, A. C. I., & Doğansoy, G. A. (2022). Makine Öğrenmesi ve Derin Öğrenme Yöntemleri Kullanılarak E-Perakende Sektörüne Yönelik Talep Tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(3), 1325-1340.

Moura, M., Zio, E., Lins, I. And Droguett, E. (2011). Failure And Reliability Prediction By Support Vector Machines Regression, *Reliability Engineering And System Safety*, Vol. 96, P.P.1527-1534.

Pirim, A. G. H. (2006). Yapay Zekâ. *Yaşar Üniversitesi E-Dergisi*, 1(1), 81-93.

Rajpal, P.S., Shishodia, K.S. Ve Sekhon, G.S. (2006). An Artificial Neural Network For Modeling Reliability, Availability And Maintainability Of A Repairable System. *Reliability Engineering And System Safety*, 91 (2006), 809-819.

Sakız, B., & Ünkyaya, G. (2018). Hava Yolu Taşımacılığı Sektöründe İflas Riski-Yapay Sinir Ağları ile Airscore Tahmini. *Öneri Dergisi*, 13(50), 159-172.

Sarı, M. (2016). Yapay Sinir Ağları ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması.

Seaton, A.V., Bennet, M. M. 1996. Marketing Tourism Products – Concepts, Issues, Cases. *International Thomson Business Press*. P. 108.

Smola, A. J., & Schölkopf, B. (2004). A Tutorial On Support Vector Regression. *Statistics And Computing*, 14, 199-222.

Olgun, S. (2009). Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemleri ve Yapay Zekâ Tabanlı Bir Talep Tahmini Modelinin Uygulanması. *Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi*.

Öncel, İ. Ç. (2013). 155 Mm. Mke Mod 274 Uzun Menzilli Topçu Mühimmatı Sevk Çemberi Kaynak Prosesinin Yapay Sinir Ağları ile İyileştirilerek Hatalı Ürün Oranlarının Azaltılması (*Master's Thesis, Fen Bilimleri Enstitüsü*).

Özdemir, A., & Özdemir, A. (2006). Talep Tahminlemede Kullanılan Yöntemlerin Karşılaştırılması: Seramik Ürün Grubu Firma Uygulaması. *Ege Academic Review*, 6(2), 105-114.

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

Tekin, M., (2009). Üretim Yönetimi Cilt 1, 6. Baskı, Günay Ofset, Konya.

Tekin, M. (1996). Üretim Yönetimi, Arı Ofset Matbaacılık, Konya.

<https://www.statista.com/statistics/267268/production-of-wheat-worldwide-since-1990/>(Erisim tarihi: 25.12.2022)

<https://www.statista.com/statistics/805044/total-population-worldwide/>(Erisim tarihi: 25.12.2022)

https://www.tcmb.gov.tr/kurlar/kurlar_tr.html(Erisim tarihi: 25.12.2022)



ÖZGEÇMİŞ

Adı Soyadı :

Doğum Tarihi :

Yabancı Dil :

Eğitim Durumu

Lisans :

Yüksek Lisans :

Yayınları (Diğer)