

T.C.
BEYKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**ONLİNE CİHAZLARIN İZLENMESİ VE VERİ
MADENCİLİĞİ KULLANILARAK ANALİZİ**

Yüksek Lisans Tezi

Tezi Hazırlayan:

Turhan Gürhan KUTLU

İSTANBUL, 2019

T.C.
BEYKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI
BİLGİSAYAR MÜHENDİSLİĞİ BİLİM DALI

**ONLINE CİHAZLARIN İZLENMESİ VE VERİ
MADENCİLİĞİ KULLANILARAK ANALİZİ**

Yüksek Lisans Tezi

Tezi Hazırlayan:

Turhan Gürhan KUTLU

Öğrenci No:

160820008

Danışmanı:

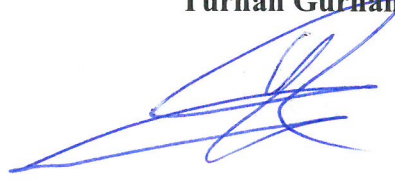
Dr. Öğr. Üyesi Atınc YILMAZ

İSTANBUL, 2019

YEMİN METNİ

Yüksek Lisans Tezi olarak sunduğum “Online Cihazların İzlenmesi Ve Veri Madenciliği Kullanılarak Analizi” başlıklı bu çalışmanın, bilimsel ahlak ve geleneklere uygun şekilde tarafımdan yazıldığını, yararlandığım eserlerin tamamının kaynaklarda gösterildiğini ve çalışmamın içinde kullanıldıkları her yerde bunlara atıf yapıldığını belirtir ve bunu onurumla doğrularım. 13/06/2019

Turhan Gürhan KUTLU



T.C.
BEYKENT ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

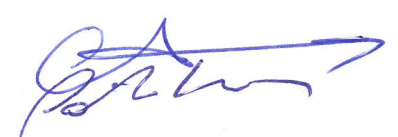
YÜKSEK LİSANS TEZ SAVUNMA SINAVI SONUÇ TUTANAĞI

Beykent Üniversitesi
Fen Bilimleri Enstitüsü Müdürlüğü'ne,

Aşağıda tez adı belirtilen yüksek lisans öğrencisi 160.820008.no'lu Turhan Gökten KUTLU.....'in 13/6/2019 tarihinde yapılan tez savunma sınavı¹ sonucunda 45 dakika süreyle sunduğu ve savunduğu tezi hakkında² oybirliğiyle BASARILI kararı verilmiştir.

Bilgilerinize saygılarımızla arz ederiz.

Anabilim Dalı : Bilgisayar Mühendisliği Anabilim Dalı
Programı : Bilgisayar Mühendisliği Bilim Dalı
Tez Başlığı³ : Online Çıkarım İzlemesi ve Veri Madenciliği
Kültürel Analizi

<u>Tez Sınav Jürisi</u>	<u>Öğretim Üyesi</u>	<u>İmza</u>
Danışman	: <u>Dr. Opr. Üye Atina Yılmaz</u>	
Üye	: <u>Prof. Dr. Erkan Sibirteoglu</u>	
Üye	: <u>Dr. Opr. Üye Ediz Soykal</u>	

¹ Jüri üyeleri, söz konusu tezin kendilerine teslim edildiği tarihten itibaren en geç bir ay içinde toplanarak öğrenciyi tez sınavına alır. Tez savunma sınav süresi en az 45, en çok 90 dakikadır. Jüri üyeleri, sınav öncesi yapılacak toplantıda, kendi aralarından danışman dışında bir üyeyi başkan seçer. Tez sınavı, tez çalışmasının sunulması ve bunu izleyen soru-cevap bölümünden oluşur. Tez sınavı, öğretim elemanları, lisansüstü öğrenciler ve alanın uzmanlarından oluşan dinleyicilerin katılımına açık ortamlarda gerçekleştirilir. Belirlenen günde yapılamayan jüri toplantısı, katılanların hazırladığı bir tutanakla enstitü yönetimine bildirilir. Bu durumda, jüri en geç on beş gün içinde toplanarak adayı tez savunma sınavına alır. (05 Ağustos 2017 tarihli 30145 sayılı Resmi Gazetede Yayınlanan Değişiklik-Madde 29-3)

² Tez sınavının tamamlanmasından sonra jüri, tez hakkında salt çoğunlukla "kabul", "düzeltme" veya "ret" kararı verir. Jüri başkanı, jüri üyelerince imzalanmış karar tutanağını, tez sınavını izleyen üç gün içinde ilgili enstitü yönetimine teslim eder. Tezi hakkında düzeltme kararı verilen öğrenci en geç üç ay içinde gerekli düzeltmeleri yaparak ve birinci fıkradaki usule göre tezini aynı jüri önünde yeniden savunur. Süresi içerisinde "düzeltme" savunmasına girmeyen öğrencinin enstitü ile ilişkisi kesilir. (Beykent Üniversitesi Lisansüstü Eğitim ve Öğretim Yönetmeliği-Madde 29-4)

³ İleride doğabilecek aksaklıkların engellenmesi için tezin başlığının yazılması gerekmektedir.

Adı ve Soyadı : Turhan Gürhan KUTLU
Danışmanı : Dr. Öğr. Üyesi Atınç YILMAZ
Türü ve Tarihi : Yüksek Lisans Tezi, 2019
Alanı : Bilgisayar Mühendisliği
Anahtar Kelimeler : Yapay Zeka, Yapay Sinir Ağları, Zaman Serileri, Regresyon

ÖZ

ONLİNE CİHAZLARIN İZLENMESİ VE VERİ MADENCİLİĞİ KULLANILARAK ANALİZİ

Çevrimiçi olacak şekilde bir ağa bağlı olarak çalışan yazıcılar üzerinde yapılması beklenen bu çalışmada, tüm bu cihazların belirli periyodlarla sayaç değerleri (baskı adedi, kilometre sayacı gibi) toplanarak kayıt altına alınmıştır. Elde edilen bu veri seti üzerinde yapılacak olan çalışmada konu cihazların verimliliklerinin artırılması beklenmektedir.

Toplanacak veriler manuel yöntemler (cihaz üzerinden kontrol) veya uzaktan bağlantı vasıtasıyla yapılabilmektedir.

Bu veriler yazıcıların seri numaralarına bağlı olarak saklanacak ve istendiğinde ulaşmak mümkün olacaktır. Daha sonra bu veriler çeşitli veri madenciliği ve yapay zeka yöntem ve algoritmaları kullanılarak, makinenin teknik kapasitesi ve teknik ömrü de göz önüne alınarak kapasitesinin altında veya üstünde çalıştığı, konumlandırılan yerin daha düşük hacimli veya yüksek hacimli cihaza ihtiyacı olduğunun tespiti, geçmiş verilerden geleceğe ait çıkarım yapma, yazıcının sayacını etkileyen faktörlerin belirlenmesi, bunların etki derecelerinin tespiti yapılması amaçlanmaktadır.

Çalışma kapsamında Excel Veri Analizi, WeKa Explorer Ve MatLab program üzerinden farklı algotirmalar ile çözümlenmeler yapılmış olup bunların tümü sonuç kısmında yorumlanmıştır.

Name and Surname : Turhan Gürhan KUTLU
Supervisor : Asst. Prof. Dr. Atınç YILMAZ
Degree and Date : Master Thesis, 2019
Major : Computer Engineering
Keywords : Artificial Intelligence, Artificial Neural Networks, Time Series,
Regression

ABSTRACT

ONLINE DEVICES MONITORING AND ANALYSIS USING DATA MINING

In this study, which is expected to be performed on printers that are connected to a network to be online, the counter values (number of prints, odometer, etc.) of all these devices are recorded and recorded in certain periods. In this study, it is expected that the efficiency of the subject devices will be increased.

The data to be collected can be made by manual methods (control over the device) or by remote connection.

This data will be stored depending on the serial numbers of the printers and will be available upon request. Then, these data are used by using various data mining and artificial intelligence methods and algorithms, taking into account the technical capacity and technical life of the machine, determining whether the location is in need of a lower volume or high volume device, making inferences from past data for the future. To determine the factors that affect the counter of the printer, to determine their degree of effect.

Within the scope of the study, different data analysis with Excel Data Analysis, WeKa Explorer and MatLab were performed and all of them were interpreted in the conclusion.

İÇİNDEKİLER

ÖZ.....	i
ABSTRACT.....	ii
TABLolar LİSTESİ.....	vi
ŞEKİLLER LİSTESİ.....	vii
KISALTMALAR LİSTESİ.....	ix
GİRİŞ	1

BİRİNCİ BÖLÜM

1. LİTERATÜR TARAMA ÇALIŞMASI	3
-------------------------------------	---

İKİNCİ BÖLÜM

2. TAHMİN YÖNTEMLERİ.....	5
2.1 Tahminleme Adımları	7
2.2 Tahmin Yöntemlerinin Sınıflandırılması	7
2.2.1 Nitel Teknikler.....	7
2.2.2 Nicel Teknikler	9
2.3 Gelecekteki Verilerin Tahminlemesi.....	13

ÜÇÜNCÜ BÖLÜM

3. VERİ SETİ VE UYGULANAN ALGORİTMALAR.....	15
3.1 Veri Nedir? Hangi Veriler Bilgi Niteliği Taşır	15
3.3 Yöntem	16
3.3.1 Tahmin Etkenleri	18
3.4 Tahmin Performans Ölçme Teknik Ve Yöntemleri	18
3.4.1 Ortalama Mutlak Sapma (MAD).....	19
3.4.2 Ortalama Mutlak Hata Yüzdesi (MAPE)	19
3.4.3 Hata Kareleri Ortalaması (MSE)	20

3.4.4 Hata Karalari Ortalamasının Kökü (RMSE).....	20
3.5 İstatistiksel Yöntemlerle Talep Tahmini	21
3.5.1 Regresyon Analizi	21
3.5.2 Korelasyon Yöntemi	24
3.5.2 Zaman Serileri Analizi Kaynaklı Talep Tahmin Yöntemleri	26
3.5.2.1 Basit Ortalamalar Yöntemi	28
3.5.2.2 Son Dönem Talep Yönetimi	28
3.5.2.3 Hareketli Ortalamalar Yöntemi	28
3.5.2.4 Ağırlıklı Ortalama Yöntemi.....	29
3.5.2.5 Ağırlıklı Hareketli Ortalama Yöntemi.....	29
3.5.2.6 Üssel Düzeltme Yöntemi	29
3.5.2.7 Jenkins Yöntemi	30
3.5.2.8 Regresif Hareketli Ortalamalar (AR-MA) Yöntemi.....	31
3.5.2.9 Otoregresif Bütünleşik Hareketli Ortalamalar (ARIMA) Yöntemi..	31
3.6 Simülasyon (Benzetim) Yöntemiyle Talep Tahmini.....	32
3.7 Yapay Sinir Ağları Yöntemiyle Tahminleme	33
3.7.1 Yağay Sinir Ağları	33
3.7.2 Yapay Sinir Ağlarının Özellikleri.....	35
3.7.3 Yapay Sinir Ağları Geçmişi.....	38
3.7.4 Yapay Sinir Ağları Yönteminin Farklı Yöntemlerle Karşılaştırılması	40
3.7.5 Yapay Sinir Ağlarının Avantajları.....	43
3.7.6 Yapay Sinir Ağlarının Dezavantajları	44
3.7.7 Yapay Sinir Ağlarının Uygulama Alanları	46
3.8 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları	49
3.8.1 Yapay sinir ağları temel yapısı	49
3.8.2 Yapay sinir ağları temel elemanları	51
3.8.3 Yapay Sinir Ağlarının Sınıflandırılması (YSA Mimarileri).....	58

3.8.3.1 İleri Beslemeli YSA.....	60
3.8.3.2 Geri Beslemeli YSA	61
3.8.4 Yapay Sinir Ağlarının Temel Öğrenme Kuralları	62
3.8.4.1 Gözetimli (Öğretmenli) Öğrenme Yöntemi.....	63
3.8.4.2 Gözetimsiz (Öğretmensiz) Öğrenme Yöntemi	64

DÖRDÜNCÜ BÖLÜM

4.UYGULAMA VE YÖNTEMLER.....	65
4.1 İstatistik Yöntemler	69
4.1.1 Zaman Serileri Veri Seti	69
4.1.2 Regresyon Analiz Eğitimi.....	69
4.1.4 Eğitim Sonuçları	72
4.1.5 Regresyon Analizi Sonuçları	73
4.1.6 Trend Analizi Sonuçları.....	76
4.2 Yapay Zeka Tabanlı Yöntemler	77
4.2.1 Yapay Sinir Ağı Veri Seti.....	77
4.2.2 Yapay Sinir Ağının Eğitimi	81
4.2.3 Yapay Sinir Ağı Modelin Çalışma Yapısı	81
4.2.4 Yapay Sinir Ağı Eğitim Sonuçları.....	86
4.2.5 Multilayer Perceptron Sonuçları.....	86
4.2.6 Naive Bayes Sonuçları.....	90
4.2.7 ANFIS Sonuçları	93

BEŞİNCİ BÖLÜM

5. SONUÇ.....	95
KAYNAKÇA	97
ÖZGEÇMİŞ.....	100

TABLolar LİSTESİ

Tablo 1 Örnek Yazıcı Grubu Sayaç Tablosu.....	16
Tablo 2 Korelasyon katsayı	25
Tablo 3 Yapay sinir ağları ve geleneksel talep tahmin metotlarının karşılaştırılması.....	40
Tablo 4 Yapay Sinir Ağları ve Geleneksel Tahmin Süreçleri Karşılaştırması.....	41
Tablo 5 Yapay sinir ağlarına karşılık gelen uzman sistemler ve elemanlar	42
Tablo 6 Uzman sistemler ve yapay sinir ağları arasındaki farklar	42
Tablo 7 Biyolojik sınırlar ile yapay sınırların karşılaştırılması.....	58
Tablo 8 Biyolojik sinir hücresi ile yapay sinir hücresinin karşılaştırılması	58
Tablo 9 Çalışma Veri Seti	65
Tablo 10 Çalışma Veri Seti (devamı).....	68
Tablo 11 Çalışma Yapılacak Dönem Tablosu.....	68
Tablo 12 2016 - 2017 Yılları Resmi Tatil İş Günü Sayı Tablosu	68
Tablo 13 Zaman Serileri Veri Seti.....	69
Tablo 14 Ay Trendi Bazında Regresyon Anlamlılık Değeri.....	70
Tablo 15 Trend Coefficients Değeri.....	71
Tablo 16 24 Aylık Veri İle Takip Eden 12 Aylık Tahmin Veri Tablosu	77
Tablo 17 Ocak 2016 Yılı İçin Hazırlanmış Örnek Eğitim Data Seti.....	78
Tablo 18 Ocak 2016 Yılı İçin Hazırlanmış Örnek Eğitim Data Seti (devamı)	79
Tablo 19 Çok Katmanlı Algılayıcı (MLP) İçin Hazırlanan Veri Seti	82

ŞEKİLLER LİSTESİ

Şekil 1 Bulanık mantık elemanları ve çalışma şekli.....	11
Şekil 2 Bulanıklaştırma – netleştirme birimli bulanık sistem.....	12
Şekil 3 Regresyon Doğrusu	22
Şekil 4 Regresyon Çizgi Grafiği.....	23
Şekil 5 Korelasyon Katsayı Grafiği.....	24
Şekil 6 Korelasyon Katsayı Yorumlama	26
Şekil 7 Zaman ayraçlı talep düzeni.....	27
Şekil 8 Yapay sinir ağlarının kara kutu benzetimi	49
Şekil 9 Yapay sinir ağları yapısı blok gösterimi.....	50
Şekil 10 Yapay sinir ağları işlem süreci	51
Şekil 11 Biyolojik sinir hücresi	52
Şekil 12 Sinir sisteminin blok gösterimi.....	53
Şekil 13 Yapay sinir hücrelerinin matematiksel yapısı	54
Şekil 14 Yapay sinir ağları mimarileri	59
Şekil 15 İleri Beslemeli YSA	60
Şekil 16 İleri beslemeli çok katmanlı yapay sinir ağları	61
Şekil 17 Geri Beslemeli YSA.....	62
Şekil 18 Gözetimli Öğrenme	63
Şekil 19 Gözetimsiz Öğrenme	64
Şekil 20 Excel Data Analysis Tool.....	69
Şekil 21 Excel Data Analysis Regression Panel.....	70
Şekil 22 Veri Seti Class Yapısı Nominal to Binary Filtre	72
Şekil 23 Lineer Regresyon Çıktısı.....	73
Şekil 24 Regresyon Eğitim Çıktısı (devamı).....	76
Şekil 25 YSA Veri Seti Parametre Ve Sınıf Dağılımı.....	80
Şekil 26 YSA Eğitim Seti Parametre Dağılımı	81
Şekil 27 MLP Çıktısı	86
Şekil 28 Multi Layer Perceptron Kullanılarak Oluşturulan Ağ.....	87
Şekil 29 MLP Sonucu Oluşan Plot Matrix	88
Şekil 30 YSA Veri Seti Parametre Ve Sınıf Dağılımı (2. Örnek)	89
Şekil 31 YSA Eğitim Sonucu (2. Örnek)	89

Şekil 32 MLP Sonucu Oluşan Sinir Ağı (2. Örnek).....	90
Şekil 33 Naive Bayes Çıktısı.....	91
Şekil 34 Naive Bayes Çıktısı (2. Örnek)	92
Şekil 37 ANFIS Ağ Yapısı	93
Şekil 38 ANFIS Sonucu	94



KISALTMALAR LİSTESİ

ARIMA	: Autoregressive İntegrated Moving Average - Otomatikleştirilmiş Asgari Hareketli Ortalama
AR-MA	: Regresif Hareketli Ortalamalar Yöntemi
ASR	: Retail Sales Forecasting. - Perakende Satış Tahminleri
GDP	: Gross Domestic Product - Gayri Safi Yurtiçi Hasıla
MAD	: Mean Absolute Deviation - Ortalama Mutlak Sapma
MAPE	: Mean Absolute Percent Error - Ortalama Mutlak Hata Yüzdesi
MSE	: Mean Squared Error - Ortalama Hatanın Karesi
ORT	: Ortalama
RMSE	: Root Mean Squared Error - Kök Ortalama Kare Hatası
YSA	: Yapay Sinir Ağlar

GİRİŞ

Günümüz teknolojisinde kullanılan akıllı cihazların tümü internete bağlanabilir ve birbiriyle konuşabilir seviyeye gelmesi amaçlanmaktadır. Bilim insanları tarafından bu ve buna benzer konular son yılların gözde çalışma alanını oluşturmaktadır. Bu sebeple birbiriyle veri alışverişi yapan cihazların uzaktan izleme sistemleri, otomasyonel sistemler de bu cihazların kontrol edilebilirliği için oldukça önem taşımaktadır.

Veri alışverişini yapan ve cihazların anlık durumunu, sorgulayan çok çeşitli agent (ajan) programlar bulunmaktadır. Bu ajan programlar network üzerinden farklı protokoller kullanarak cihazlar ile iletişime geçer. Cihazlardan mevcut verilerini toplar ve bir bilgisayar ortamına aktarır. Daha sonra bu veriler kullanılarak çeşitli araştırmalar yapılabilmektedir. Bu veriler kısa, orta ve uzun vadeli analizler yapmak için kullanılabilir.

Yapılan çalışmada, istatistiki yöntemler ve yapay zeka tabanlı metodlar kullanılarak perakende sektörü bünyesinde bulunan kurumsal bir firmanın gerçek verileriyle çeşitli algoritmalar kullanılarak hesaplamalar yapılmıştır.

Çalışmanın amacı geçmiş verileri kullanarak geleceğe ait tahminleme yapılması ve mevcut duruma etki farklı parametlerin etki seviyesini ölçmektir. Bu bilgiler ışığında yapılan çalışmanın geri dönüşü olarak kurumsal firmaların forecast planlama bağlamında ciddi maliyet hesaplamalarına önceden tahminleme ve hazırlıklı olması anlamı taşımaktadır.

İkinci bölümde, çalışmada giriş olarak literatürde yapılan benzer çalışmalar araştırılacak ve bu çalışmalar ile aradaki benzerlik ve farklılıklar ortaya koyulacaktır.

Üçüncü bölümde, tahmin yöntemlerine genel bir bakış ile değinilecektir. Tahmin yöntem ve adımları ve bu yöntemlere ait sınıflandırmalar anlatılacaktır. Sınıflandırma dahilinde nitel ve nicel yöntemler ayrı ayrı başlıklar halinde değerlendirilecektir.

Dördüncü bölümde, veri nedir, hangi bilgiler veri niteliği taşır bu konulara değinilecektir. Çalışmada kullanılacak yöntem ve tekniklere ait bilgiler verilecektir. Tahmin performansı ölçme teknik ve yöntemleri başlığı altında MAD, MAPE, MSE, RMSE konuları detaylandırılacaktır. Bunların yanısıra istatistiki yöntemler ile talep

tahminine ait algoritmalar anlatılacaktır. Bunlardan bazıları; Regresyon, Korelasyon, Zaman Serileri Analizi gibi, farklı birçok hesaplama yöntemleri detaylandırılarak paylaşılacaktır. Bu yöntemlere ek olarak, Yapay Sinir Ağları konusuna değinilecektir. YSA'nın temel yapısı, özellikleri, standart yöntemlere göre artıları ve eksileri, uygulama alanları ve çeşitli yöntemlerden bahsedilecektir.

Beşinci bölümde, düzenlenen veri seti kullanılarak uygulama ve kullanılacak algoritmalara ait çalışmalar yapılacaktır. Çalışma dahilinde kullanılması planlanan tüm yöntemler burada yer almaktadır. Daha sonra bu analizler sonucu çıktılar sonuç bölümünde değerlendirilecektir



BİRİNCİ BÖLÜM

1. LİTERATÜR TARAMA ÇALIŞMASI

2015 yılında Genel Tıp Dergisi'nde yayınlanan bir çalışmada hastalık teşhisi ve bu tanıya bağlı sağkalım oranları incelenmiştir. Bu çalışmadaki veriler yaş, cinsiyet, preoperatif odyometrik sonuçlar, kulak patolojisi ve 150 hasta ile ilgili cerrahi detaydan oluşmaktaydı, ancak hastalar için postoperatif işitme eşiği hesaplandı. Bu çalışmada geliştirilen en iyi sinir modelleri, test verileri için% 84 oranında doğru tahminlere sahipti [1]. Kadir Tok'un 2017 yılında yayınladığı bir başka çalışmada romatoid artritli ve romatoid olmayan kişilerin verileri eğitim ve veri seti olarak kullanılmıştır. Kullanılan ağ 0 hata ortalaması 500 ve 1500 yineleme aralığına ulaştı. Doğruluk yüzdesine, geri yayılım algoritmasıyla% 82, Perceptron algoritmasıyla% 71 ulaşıldı [2]. Ali Aslantaş'ın sağlık alanında yaptığı çalışmada, yapay sinir ağları kullanılarak metastazın ayırıcı tanısında% 92.3 doğruluk,% 94 duyarlılık ve% 86.67 özgüllük oranı saptanmıştır [2]. Mustafa Coşkun tarafından 2013 yılında yapılan bir çalışmada, EEG bazlı anestezi derinliği çok katmanlı bir sensör kullanılarak tahmin edilmiş ve% 95 doğruluk elde edilmiştir [3]. Kemik rezorpsiyonu teşhisi üzerine 2013 yılında yapay sinir ağları kullanılarak yapılan Mustafa İstanbullu çalışmasında, yapılan sınıflama sonuçlarının% 86'sı erken dönem görüntülerinde osteoporoz başarılı bir şekilde teşhis edilmiştir [4]. 2012 yılında epilepsinin teşhisi için yapılan bir başka yapay sinir ağı çalışmasında Nesibe Yalçın, parçacık sürüsü optimizasyon yöntemini kullanarak% 98 sınıflandırma doğruluğu elde etti [6]. Araştırmada Gülhan Toğa, 2012 yılında koroner arter stentleme sonrası ölüm oranlarını indirgenmemiş veri seti ile oluşturulan yapay sinir ağları kullanarak incelemiştir. Eşzamanlı sınıflandırma modelinde hastanede ölümlerin% 97,23'ü, taburcu edildikten sonra ölümlerin% 94,44'ü ve ölümlerin% 90,87'si. doğru sınıfa [5] atanmış. Yapay sinir ağları aracılığıyla fibromiyalji sendromu tanısını biyomedikal sinyallerle tanı koyan Özhan Özkan, bu çalışmada 2012 yılında% 100 doğruluk ve% 100 test verilerinin elde edilmesini sağlamıştır [8]. Fatma Aşkın'ın 2011 yılında sol atriyal çapı karşılaştırması ana bileşen regresyonu, kısmi en küçük kareler regresyonu ve yapay sinir ağı tahminleri yapay sinir ağı modellemesinde en başarılı sonuç olmuştur [9]. Yashar M.

Jwma tarafından yapay sinir ağı tarafından değerlendirilen çalışmada, sınıflandırma sistemlerinden elde edilen sonuçlar değerlendirildi. Bazal bileşen analizi% 99,28, bağımsız bileşen analizi% 95,71 ve dalgacık dönüşümü% 98,92 olarak elde edilmiştir [6]. Hakan Aydemir'in apne hastalarının çalışmasında yapay sinir ağı ile tanıyı belirleme yeteneği% 96'ya ulaştı [7].

Selvakumar ve ark. 2010 yılında nükleer imajlardan gelen patlamanın enerjisini hesaplamak için bir çalışma yapılmıştır. Fotoğraflardan elde edilen enerji ölçümlerinde% 90 doğruluk bulunmuştur [8].

Sumaya Abusaleh ve meslektaşları, 2017 yüksek kayıtlarında gerçekleştirdikleri sınıflandırma çalışmasında% 94,8 başarı elde etmişlerdir [13].

2016'da yayınlanan çalışmalarında, Daniel T.Schmitt ve arkadaşı, videoda yaptıkları yapıda tahmini olarak% 86.03 oranına ulaştı. [9].

2015 yılında yayınlanan çalışmalarında Robert ve arkadaşı Nükleer ateş duvarlarında sıcaklık analizi yapmıştır [10].

Yapay talep ağlarının uygulanması ve ürün talep tahminlerinin uygulanması amacıyla. Tüm işletmeler gelecekteki statülerini sabit tutmak veya geliştirmek için iyi bir plana karar vermek zorundadır. Tahminin amacı, işletmelerin gelecekte karşılaşılabileceği durumları önceden tahmin etmek ve çeşitli yöntemler kullanarak önleyici tedbirler almaktır. Bilgisayarlar tabanlı yapılan çokça çalışma kapsamında, anlaşıldı ki yapay zeka kavramı insan beyninin bilim adamları tarafından modellenmesinin bir sonucu olarak hayata geçti. Yapay sinir ağlarının doğrusal olmayan problemleri çözmede ve son derece güvenilir sonuçlar sağlamada etkin kullanımı bu yöntemi yaygın olarak kullanmıştır. Bu çalışmada, Malatya ilinin kuru kayısı ürününün ihracat talep tahmini, istatistiksel talep tahmin yöntemlerinin yapay sinir ağı modelleri kullanılarak yapılmıştır [1].

Daniel T.Schmitt ve arkadaşının 2016 yılında yayınlanan çalışmalarında video üzerinden gerçekleştirdikleri yapıda %86.03 tahmin oranına ulaşmışlardır[9].

İKİNCİ BÖLÜM

2. TAHMİN YÖNTEMLERİ

İlgili bölümde talep tahmin tanımı, adımları, yapılabilirliği, ve tüm bu yöntemlere değinilmektedir.

Talebin temel tanımı, tüketicinin bir ürün, hizmet gibi faktörler için belirlenen fiyat aralığından satın almak için hazır olduğu miktara söylenmektedir. Bu talebi direkt ve endirekt etkileyen faktörler şu şekilde sıralanabilir;

- Fiyat
- Gelir düzeyi
- Alışkanlıklar
- İhtiyaç Seviyesi
- Çevresel Faktörler
- Mevsimsel Faktörler

Tahmine kısaca, geçmiş baz alınarak gelecek hakkında anlamlı sonuçlar çıkartma diyebilinir.

Talep tahmini, bir firmaya ait ürünün mevcut satışlarının gelecekteki halini belirleme ve bilmek adına, geçmişe ait verileri düzenleme ve tüm bunların analiz edilme sürecinin tümüne söylenebilir. Ürün veya ürünlerin satış miktarlarını, tüketici talebinin hangi ürün veya ürünler üzerinde yoğunlaşacağını ve tüm bunların gerçekleşmesi beklenen tarih aralığını gösterebilir.

Talep tahminlemede yaparken üç temel yöntemden bahsedilebilir. Bu yöntemleri; şu şekilde sıralayabiliriz:

- Kantitatif
- Kalitatif
- Yapay Zeka Tabanlı

Teknolojik gelişme ile yapay zeka altyapılı yöntemler de oldukça kullanılmaktadır. Kalitatif yöntemler, çıkarımlar ve deneyimleri baz alırken, kantitatif yöntemler daha çok istatistiksel ve matematik tabanlı bir yöntemdir. Bu iki klasik yöntemle çözümlenemeyen veya beklenen performansın alınmadığı senaryoda ise yapay zeka yöntemleri öne çıkmaktadır.

Nitel tahminleme, bir konuda o konuya hakim kimseden alınan öneri, görüş ve tahminler esas alınmaktadır. Aynı veriler ile yapılan çalışmada birden çok kişi ve kişilerin birbirinden farklı tahminleme yapmaları mümkündür. Bu tahmin yöntemi uygulama bakımından oldukça kolay ve fazla zaman almamaktadır. Zaman ve maliyet bakımından ayrıca üstün bir istatistiksel işleme ihtiyaç olmadan uygulanabilmesi başlıca tercih sebebi olarak düşünülebilmektedir.

Nicel yöntemler daha çok istatistiksel yöntemlerdir. Bu yöntem için elimizde konuyla alakalı yeterli düzeyde sayısal veri varsa kullanılabilir. Geçmiş verinin sayısal olarak ifadesine ek değişken verinin geçmişte yaptığı yapıyı ileriki dönemlerde de devamının mümkün olma şartını sağlaması durumunda kullanımı olasıdır.

Talep tahmini çoğunlukla dört farklı durum için yapılır. Bunlar aşağıdaki gibi sıralanabilir;

- Çok kısa
 - Kısa
 - Orta
 - Uzun
-
- Çok kısa vadeli: Çoğunlukla günlük veya haftalık tahminlerdir. Güncel stoğu kontrol etmek, haftalık satışı kontrol etmek veya kısa vadeli çıkarımlar yapmak için kullanılabilir.
 - Kısa vadeli: Bir hafta ila altı aylık periyodlar için kullanılmaktadır. Üretim kapasitesini vb. durumlarda işgücünü uyarlamak için tasarlanmıştır.
 - Orta vadeli: Altı ay ila beş yıl arasında kullanılmaktadır. Belirsiz tedarik süresi için satın alımların yapılması kullanılabilir.
 - Uzun vadeli: Beş yıllık ve daha uzun süreli tahminler için kullanımı mümkündür.

2.1 Tahminleme Adımları

1. Etkileyen faktörlerin belirlenme: Tahminleme yapmadan önce bu çalışmada sonucu etkilecek faktörlerin tek tek belirlenmesi gerekmektedir.
2. Veri toplama: Etki faktörlerin belirlenmesinin ve bu faktörler için ilgili verinin toplanması, talep tahmin çalışmasını etkileyen en önemli aşamadır. Kullanılacak veriler, daha önceki dönemlere ait veriler ile ülke ekonomisinin ekonomik veya ekonomik verileri olabilir.
3. Tahmin süresini belirleme: Tahmininin yapılacağı zaman dilimi belirlemelidir. İlgili zaman diliminde kestirim çalışması yapılmalıdır.
4. Tahmin yöntemi ve hata hesaplamasının belirlenmesi: Arz incelemesinden beklenen performansa durumuna bakılarak tahmin yöntemi seçilmelidir.
5. Çıkarım sonuçlarını ve bunların geçerliliğini araştırmak: Elde edilen çıktı ile reel değerler arasındaki farkı belirleme, çıkan farkın nedenlerini araştıran aşamadır. İlgili sebeplerden en değerlisi de toplanan verilerin doğruluğuna göre sonuçlanmaktadır.

2.2 Tahmin Yöntemlerinin Sınıflandırılması

Tahminleme yöntemleri temel düzeyde üç farklı sınıfa ayrılabilir. Bunlar aşağıdaki gibidir;

- Nitel
- Nicel
- Uzman Görüşü

2.2.1 Nitel Teknikler

Veriler ışığında, bilimsel teknikler aksine duygu kişiseldir ve adli olarak yapılır. Tahminleme performansı diğer yöntemlere oranla daha düşüktür, çünkü tahmin yöntemi bilimsel verilere dayanmamaktadır.

Uzman görüşünün alınması: Öngörü, ilgili konuda uzman olan personelin tecrübesine, bilgisine ve sezgisine dayanmaktadır. Bu kişi finans, satın alım, üretim, satış veya yönetim kurulu üyesi olması mümkündür. Bu yöntem az zamanda karar verirken kullanılabilir. Konu verilerle başa çıkmak için zaman kazandırabilir. Bu yöntem daha avantajlı olarak kabul edilir, çünkü basit, uygulaması kolay ve ucuzdur. Ancak, hepsi kişisel görüşlerle ilgili olduğu için, yanlış sonuçlara ulaşma şansı diğerlerinden daha yüksektir.

Delphi tekniği: Bu teknik, bir ürünün veya çıktının beklenen gelecekteki talebini tahmin etmek için kişisel tartışmalara ve tartışmalara ihtiyaç duymadan uzmanların talebin gelecekteki değerini belirleyip müzakere etmelerinin bir yoludur. Delphi tekniği, 1950 li yıllarda Amerika Birleşik Devletleri topraklarında bulunan ve RAND firmasında bünyesinde çalışan, Norman Dalkey & Olaf Helmer isimli iki kişi ve araştırmacılar tarafından geliştirildi ve uygulandı. Bu yöntemin temel amacı ise; Gelecek hakkında öngörüler yapmak, uzmanların öngörülerini paylaşmak, fikir birliğine varmak. Bu teknik çoğunlukla siyasi duygusal, ortamlardaki sonuç için karar alma durumlarında ve bu duruma ek kararın üstün gruplardan etkilenmesi muhtemel olduğunda kullanılmaktadır. Bu yöntemi kullanan uzmanlar çoğunlukla ardışık anketlere uygulamaktadır.

Basitçe üç temel işlevi aşağıdaki gibidir:

1. Katılım gizliği
2. Kitle cevabının istatistiksel analizi
3. Kontrollü geribildirim

Anket yönetimi: Yeni bir ürün piyasaya sürüldüğünde veya yeni bir ürün geliştirildiğinde talebi tahmin etmek için anket yapma yöntemidir. Büyük gruplara ulaşmak ve araştırmayı geniş kitlelere dayandırmak oldukça basittir. Bu durum araştırmacıya finans ve zaman olarak katkı sağlar. Ancak, ilgili teknikle güven aramak çoğunlukla zordur. Bu araştırmalarda ayrıntılı bilgi almak hiç kolay olmamaktadır. Eksileri, insanlara ait soruyu benzer şekilde anlamalarını ayrıca cevaplarına şeffaf olmalarını ve rastgele cevaplar verememeleri mümkündür. Genellikle, anketörün kontrol etmesinin bir alternatifi yoktur.

Senaryo kestirimi: Senaryolar standart öngörü yöntemlerinin aksine farklı geleceklere temsil eder ve ekonometrik modelleri dışlayan konuları ve nitel görüşleri içerir. Senaryo analizi, hem bireysel düşünce farklılıkları hem de gelecekle ilgili belirsizlikleri modelleme yeteneği sağlayarak yaratıcılığı teşvik eder.

Senaryo analizi ayrıca, farklı gelecek senaryoları için seçilen stratejilerin esnekliğini ve esnekliğini test etmeyi mümkün kılar. Böylece, stratejilerin kırılmasıyla ilgili göstergelerin belirlenmesi ve izlenmesi daha kolaydır. Kaynak planlaması, belirlenen stratejilerle ilişkili riskleri azaltabilir.

Senaryo kestirimi ayrıca dip çizgisine yakın alternatif planlar oluşturmaya da yardımcı olur. Böylece, cihazın adaptasyon hızı değişen şartlarla yükselir. Geleceğin net olmamasına karşı ön hazırlık için sabit olmayan durumlar karşısında başvurulacak noktaların belirlenmesi, kritik ve stratejik düşünme zenginliğini yükseltir.

Satış gücü tahminleme birleşimi: İlgili kişiler, sorumlu oldukları bölgelerde hangi durumların, nasıl bir gelecek olacağını tahmin eder. Kestirim yaparken, önceki güncel trendi göz önünde bulundururlar. Toplam tahmin sonrasında her bir kaynak tarafından gelen bilgilere göre birleştirilir. Burada bulunan durumda, görevli kişi henüz yeni ise, piyasa bilgisi zayıf olacağından uygulanması doğru olacaktır.

2.2.2 Nicel Teknikler

Kantitatif kestirim yöntemleri, evvelki dönemlere ait gerçek kayıtlı değerlere sahip istatistiksel yöntemlere denilmektedir. Talebin gelişimine etkileyen faktörler ve bunlar ile gelecekteki dönemler için talep miktarı arasındaki ilişkinin benzer eğilimler olduğu söylenmektedir. Önceki döneme ait veriler istatistiksel yöntemler kullanılarak değerlendirilmekte ve gelecek dönemler için ihtiyaç miktarları kullanılmaktadır. Bu yöntemler ise; zaman serileri analizi, nedensel yöntemler olarak iki başlık olarak ayrılmaktadır.

Zaman serileri: Bu serilerde belli bir eğilim, benzeşme olup olmadığını kontrol edilerek belirlemeli ve gelecek için tahminlerde bulunulabilir. Bu verilerin tümü geçmişe ait dönemsel verilerdir. Bu analiz yöntemi, geçmiş dönemlere ait değişkenli metodunu

inceyerek, ilgili süreci en iyi temsil edebilen kurguyu ve modeli oluştururlar. Model ile gelecekteki gereksinimler öngörülebilmektedir.

Nedensel durumlar: Nedensel yöntemler, onu etkileyen faktörlerle ilgili faktörleri tahmin etmeyi amaçlayan yöntemlerdir ve bu faktörlerdeki değişikliklere göre tahminler yapılmaktadır. Talep ve buna bağlı etki faktörlerini ortaya çıkarar sebep ve sonuç ilişkisini ortaya çıkartmaktadır.

Yapay zeka temelli yöntemler: İnsan düşüncesini anlayabilmek ve insana benzer bir bilgisayar düşüncesi geliştirme olarak anlamlandırılabilir. Farklı bir deyişle, insana özgü algı, vizyon, düşünebilme, karar alma, bilgi vb. özelliklere sahip bilgisayarlardır.

Yapay zeka temelli yöntemler çoğunlukla düzensiz problemleri çözebilmek için en doğru ve sonuçlayıcı yöntemlerden bilinir. Tahmin yöntemleri için literatürde en sık tercih edilen yapay zeka yöntemleri sırasıyla:

1. Bulanık mantık
2. Yapay zeka
3. Genetik algoritma

1. Zadeh dünya üzerinde ilk defa 1965 yılında bu kavramı piyasaya çıkaran isim olmuştur. Çalışmalarında, girdi verilerin farklı küme gruplarında farklı üyelik seviyesinden bahsetmişti ve girdilerin çıktı haline dönüşmesinin ilgili kümeler vasıtasıyla yapılabileceğini betimlemiştir. Yöntem, deneyim tabanlı verilerin veya sayısal olarak betimlenemeyen verilerin yorumlanması için oldukça sık kullanılır.

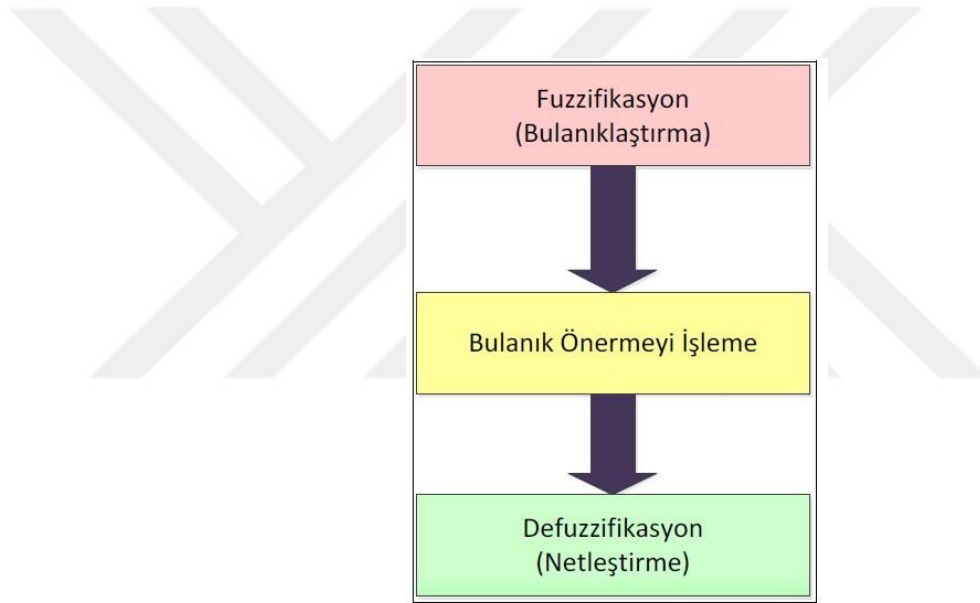
Bulanık grup ve kümeler, birbirinden değişik küme üyelik derecelerine sahip birtür öğeler kümesidir. Küme, ikiden fazla kısmi üyeliği içeren klasik küme teorisinde ikili üyelik kavramını evet-hayır biçimine değiştirip dönüştürmek anlamında kullanılmaktadır.

Bir kavramı tanımlayabilmek, bir amacı aktarmak veya bir sistemi tanıtmak belirsizlik olarak adlandırılır. İnsanın zihinsel seviyedeki algı farklılıkları, öznel davranışlarının, ifadelerindeki ve amaçlardaki belirsizlikler, bu kavram ile açıklanabilir.

Bu algoritmanın, bulanık mantığın başlıca özellikler aşağıdaki gibi sıralanabilir:

1. Kesin değerleri baz alan düşünme sistemine alternatif olarak yaklaşık düşünme yöntemini kullanır.
2. Bazı bilgiler, örneğin dilsel ifadeler gibi (büyük, küçük vb.) şekilde sunulur.
3. Bu yöntemde her şey belli bir aralıkta belli bir oranda gösterilir.
4. Çıkarım süreci, dilsel ifadeler ile tanımlanan kurallarla gerçekleştirilir.
5. Bütünüyle mantıksal sistemler belirsiz olarak ifadelendirilir.
6. Matematiksel modellerle elde edilmesi zor hesaplamalar için oldukça iyi çalışır.

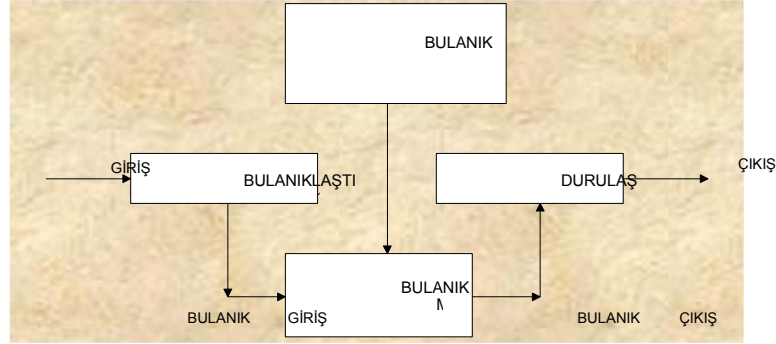
Bulanık mantık hesaplama süreci Şekil 1 ' de gösterildiği gibidir:



Şekil 1 Bulanık mantık elemanları ve çalışma şekli

Bulanıklık, giriş bilgilerini bir sistemden dil nitelikleri bulunan ve bu değerleri sembolik değerlere evrimleştirme işlemi olarak betimlenebilir. Üyelik fonksiyonu kullanılarak giriş bilgisine ait bulanık kümeler belirlenir ve girilen değerler dilsel değişkenler olarak belirlenir. Blur, bulanık önerme değişkenlerini ve çözülecek problemle ilgili karar kurallarını belirlemek ve üyelik fonksiyonunu oluşturmak için kullanılan sürecin adıdır. İşlem ağlar; Çözüm etki alanından tek bir değer alma işlemi olarak adlandırılır. Kesin değer, ağ yöntemlerinden biri kullanılarak belirlenir.

Bulanıklaştırma – netleştirme birimli bulanık sistem Şekil 2 ' de gösterildiği gibidir:



Şekil 2 Bulanıklaştırma – netleştirme birimli bulanık sistem

2. Bu yöntem diğer yöntemlerine kıyasla çokça bizim karşımıza çıkan kullanılan ve tercih edilen yöntemlerden biridir. Bu yöntem mevcut örneklerden eğitilip genel kullanıma alınabilecek kapasitededir ve bu yöntem çok esnek ve güçlüdür.

3. Bu yönteme Genetik algoritmalar kısaca “GA” olarak kullanılabilir. Gündelik hayatta çözülemeyen veya çözümlenmesi zor ve karmaşık problemleri hesaplamak amacıyla kullanılabilir. Genetik algoritmalar, naturel seleksiyon temellerine dayanan bir araştırma ve optimizasyon çıkarım yöntemi olarak düşünülebilir. Geleneksel hesaplama ve optimizasyon yöntemlerine kıyasla farklılık gösteren bu yöntem, parametre setinden ziyade önceden kodlanmış formatları kullanmaktadır. Bu algoritmalar; programlama, mekanik öğrenme, başarılı uygulamalar fonksiyonel optimizasyon, tasarım ve hücrel üretim gibi alanlarda kullanılabilir.

Bu algoritmalar aramanın ne şekilde çalıştığı alt küme kavramı ile açıklanmaktadır. Alt diziler, genetik algoritmaların davranışını açıklayan teorik olgulardır. Alt küme kavramı ile arasında bulunan ve benzerlik durumunu tanımlama görevini üstlenmektedir. Bunun gibi alt dizilerin 2 çeşit özelliği bulunmaktadır. Bunlar alt kümeye olan uzaklık ve alt kümenin uzunluğudur şeklimde yorumlanabilir. Sonuç puanı, mevcut kümeleme düzenindeki sabit konumların sayısı olarak adlandırılır. Alt

kümenin uzunluğu; mevcut altküme düzeninde belirlenmiş ilk ve son konum arasındaki mesafe. Yücelik ve alt gibi kavramlar, genetik algoritmalarda oldukça önemli rol oynarlar.

Bu tip bir algoritma, bir grup çözüm uzayında bulunan ve her noktayı bir çeşit kromozom olarak adlandırılan ikili bir tür bit dizisi kullanarak kodlar. Tüm noktaların bir takım uyumluluk değeri bulunmaktadır. Sadece tekil bir nokta tercihi yerine bu durumu popülasyon şeklinde birçok noktayı hedef alarak korur. Her jenerasyonun genetik algoritması, melezleme ve mutasyon gibi buna benzer genetik etmenleri de kullanarak bir tür yeni bir popülasyon oluşturmaktadır.

Genetik algoritmaya ait işlem adımlarını aşağıda olduğu gibi sıralayabiliriz:

1. Araştırma alanındaki olası bütün çözümler diziler olarak kodlanmıştır.
2. Tipik olarak, rastgele bir tür çözüm kümesi seçilir ve bir popülasyon olarak kabul edilir.
3. Tüm diziler için bir tür uygunluk oranı, değeri hesaplanır ve çıkan bu değerleri ilgili dizilerin kalitesi hakkında bilgi sağlar.
4. Bir grup rastgele seçilir ve belirli bir olasılık değeri ile çarpılır.
5. Yeni kişilerin uyum değerleri hesaplanır ve geçiş ve mutasyona tabi tutulur.
6. Yukarıdaki işlemler önceden belirlenmiş sayıda nesiller için devam eder.
7. Belirlenen kayış sayısına ulaşıldıktan sonra yineleme sonlandırılır. Amaç işlevine göre en uygun dizi seçilir.
8. Modeller, genetik bir algoritma kullanarak veri yığınlarından elde edilir. Talep tahminini belirlemek için bir yöntemdir.

2.3 Gelecekteki Verilerin Tahminlemesi

Firmaların tedarik zinciri departman yöneticilerinin tahminleme yöntemleri hakkında bilgi sahibi olmaları şirket yönetim süreçlerinde önem taşımaktadır. Tahminler istatistiki olmadığı sürece hataya açıktır. Ancak istatistiki veriler de doğru sonucu vermeyebilir. Bu sebeple hata paylarının da mutlaka göz önüne almak gereklidir. Öngörü hatalama paylarının ciddiyetini anlayabilmek adına birbirinden farklı otomobil satıcılarını ele alalım. A satıcısı satışlarının tahmini 100 ile 1900 arasında olacağı tahmin edilmektedir, B satıcısının satış tahmini ise 900 ile 1100 birim arasındadır. A ve B satıcılarının ortalama satışı 1000 birim olsa dahi öngörü doğruluk oranları göz önüne alındığında her iki satıcı için de veri kaynak politikaları oldukça farklıdır. Dolayısıyla tahminleme hata payı birçok tedarik zinciri kararları alınırken anahtar girdi olarak yer

almalıdır. Ancak tüm bunlara rağmen çoğu şirket bu alt detayı göz önünde bulundurmamış için insani faktörlerle tahminleme yapmakta ve sonuç olarak olması gereken çıktıdan oldukça uzak değerler elde etmektedir.

Daha uzun vade içeren tahminler çoğunlukla kısa vadeli tahminlerden daha çok doğruluktan uzaktır. Uzun vadeli tahminler kısa vadeliyle oranla daha yüksek hata payı içerirler. Standart sapma değeri daha fazladır. Japonya menşeli firma olan “Seven-Eleven”, ilgili kilit özelliğini performans geliştirme ve iyileştirmede kullanmaktadır. İlgili firma siparişlerine oldukça kısa süreler dahilinde yanıtlama ve cevaplama sürecinin uygulamaya almıştır. Örnekleme gerekirse, örnek mağaza saat 09:00 gösterdiğinde sipariş aldıysa bu siparişi gün içinde saat 18:00 ‘ı göstermeden teslim etmiş durumda oluyor. Bu sebeple mağaza yöneticisi asli satışından yaklaşık 12 saat kısa süre öncesine kadar sadece mevcut akşam ne satılacağını öngörmesi gerekir. Uzun olmayan teslim süreci yöneticinin ürün satışını etkileyecek, hava durumu vb. güncel ve değişken değerleri de değerlendirme sürecine katmasına olanak sağlayacaktır. Mevcut tahminin mağaza yetkilisi talebini yaklaşık bir hafta öncesinden öngörmesine oranla daha doğru sonuç almasında faydalı olur.

Toplam tahminler, günlük / küçük tahminlerden daha hassastır, çünkü ortamdaki daha küçük oranlarda standart bir sapma derecesine sahip olma eğilimindedirler. Örneğin; ABD'nin (ABD) Yıllık Gayri Safi Yurtiçi Hasıla (GSYİH) yılını yüzde 2'den daha az bir hatayla tahmin etmek kolaydır. Ancak, bir firmanın yıllık kazancını% 2'den daha az bir hatayla tahmin etmek daha zordur. Bir X ürünü için bile, yıllık geliri yüzde 2'den daha az bir hatayla tahmin etmek daha da zordur. Her üç tahminde de farklı derecelerde tuş kombinasyonu / toplamı bulunur. GSYİH, birçok şirket arasında birleşmiştir ve bir şirketin kazancı, çeşitli çizgiler arasında bir kombinasyondur. Toplama ne kadar büyük olursa, tahminin doğruluğu olasılığı da o kadar yüksek olur.

Genel olarak, bir şirket için tedarik zincirinde ne kadar yüksekse veya müşteriden ne kadar uzak olursa, aldığı bilgi o kadar az doğru olur. Bunun klasik bir örneği kampçı etkisi olabilir. Kampçı etkisi, talepler son müşteriden uzaklaştıkça talebin değişimini de arttırır.

ÜÇÜNCÜ BÖLÜM

3.VERİ SETİ VE UYGULANAN ALGORİTMALAR

Çalışmada kullanılacak veri seri ve hesaplama yöntem, algoritmalara bu kısımda değinilecektir.

3.1 Veri Nedir? Hangi Veriler Bilgi Niteliği Taşır

Araştırmada en değerli ve olmazsa olmaz olan şey veridir. Bir çalışmada araştırma yapmak, sonuca ulaşmak için ilk gereklilik veridir. Veriler; sayılabilen, ölçülebilen, deney yapılabilen, sayısal veya sözel olabilirler. Sözkonusu verinin hacmi yapılan çalışmanın büyüklüğüne, kapsamına, beklentiye göre ufak çaplı veya çok büyük ölçülerde olabilir.

Sözkonusu çalışmada kullanılacak veriler bir perakende market zincirinin gerçek verilerdir. Bu bağlamda yapılacak çıkarımlar gerçek hayatta kullanılabilir. Kullanılacak verilerin tümü sayısal verilerdir. Bu veriler üzerinden istatistiki hesaplamalar yapılacak ve tutarlılığı tespit edilecektir. Çıkacak sonuca göre gelecek yıllara ait tahminlemede kullanılacak olup ciddi oranda katkı yapması öngörülmektedir.

Geçmiş dönemlere ait sayaç değerleri baz alınarak mevcut dönem, gelecek dönem değer tahminlemesi yapılabilir. Bu tahminlemeye ek olarak, baskı adedini etkilediği düşünülen diğer faktörle de bir çalışma yapılabilir. Örneğin; ilgili takvim yılındaki resmi tatiller, yazıcıya ait arıza durumu vb. Değişkenlerde hesaplamaya dahil edilerek farklı çıkarımlarda bulunulabilir. Buna göre finans tabloları ve bütçelemeler bu raporlar oluşturulurken bu çalışmadan faydalanabilmelidir.

Bu çalışmada, regresyon analizi ve trend analizi yöntemleri kullanılarak gelecek dönemlere ait çıkarımlar yapılmak istenmektedir. Çıkacak sonuçlar baz alınarak, takip eden dönemlerde oluşturulacak bütçe tablolarının oluşturulmasında büyük rol oynayacaktır.

Ön çalışma olarak 1 ila 10 adet arasında yazıcı pilot olarak belirlenecek olup bu grup üzerinde çalışma yapılacaktır. Çıkan sonucun güvenilirliği tespit edilecek ve bu

bağlamda gerçek verilerle kıyaslanacaktır. Güvenirlik yüzdesi yüksek olması durumunda tüm cihazlara, yani ortalama 6000 adet yazıcı için uygulanarak bu konuda bir bütçe tahminlemesi etkin olarak yapılması beklenmektedir.

Tablo 1 Örnek Yazıcı Grubu Sayaç Tablosu

SERI_NO	KOD	FORMAT	DURUM	SEZON	SEGMENT_TANIM	SATIS_ALAN	SANAL	Oca.16	Şub.16	Mar.16
RNV01335	3672	5	1	0	2	3815	1	3165	2389	2410
RNV05616	4721	1	1	0	24	464	0	0	0	0
RNV04123	4559	1	1	0	44	409	0	1951	1293	1431
RNV05649	4762	1	1	0	21	250	0	2096	2065	1788
RNV05619	4772	1	1	0	21	437	0	2572	2839	2818
RNV05674	3328	1	1	0	21	445	0	2123	3583	2314
RNV06307	4315	1	1	0	31	287	0	1978	2098	1681
RNV08124	4720	1	1	0	21	550	0	2967	3045	2989
RNV05632	3281	1	1	0	21	530	0	2767	3613	2960
RNV02516	4285	1	1	0	11	449	0	1609	1715	1941

Tablo 1 'de yazıcı bazlı aylık toplam sayaç bilgisi bulunmaktadır. Bu mağazaya ait kullanılan yazıcının 3 yıllık gerçek sayaç değerleri paylaşılmıştır. 2016 ve 2017 yılları baz alıp kullanılarak regresyon yöntemi ile 2018 yılına ait baskı adetlerini yani sayaç değerlerini tahmin etmek amaçlanmıştır. Aynı zamanda 2016 ve 2017 verilerini kullanarak yapılacak çalışmada 2018 verileri tahmin edilecektir. Böylece 2018 gerçek verisi ile tahmin verileri karşılaştırılacak olup çalışılan algoritmanın güven endeksi net olarak ortaya konulacaktır. Böylece 2019 ve 2020 tahminleri de yapılarak bütçeleme de kolaylıklar sağlanması amaçlanmıştır.

3.3 Yöntem

Yapılacak araştırmada kullanılması düşünülen algoritma yöntemleri için öncelikle eldeki verilerin detaylıca incelenmesi ve varolan verilerin en doğru sonuç verilmesi beklenen algoritma seçilerek bu algoritma üzerinde kurgulanması ve hesaplatılması

gerekir. Aksi halde eldeki veriyle uyuşmayan bir algortima veya tam tersi senaryoda yapılacak çalışma doğru sonuç vermeyecektir.

Kullanacağımız veriler nitel mi yoksa nicel veriler mi? Nicel veriler sayılabilen ve ölçülebilen verilerdir. Nitel veriler, sayılamayan ve ölçülemeyen verilerdir. Bu ayrımı iyi yapmak çalışmanın devam edecek süreci için oldukça önemli rol oynamaktadır. Eldeki veriler nitel veriler ise, su, bakliyat, patlıcan, yönetici, ay vb. Veriler olması durumunda bu veriler nitel veriler olarak adlandırılır. Ancak bu verileri nicel verilere yani sayılabilen verilere dönüştürmekte mümkün olabilmektedir. Ay olarak adlandırılan verilere, 1, 2, 3, (1.Ay, 2.Ay, 3.Ay) şeklinde dönüştürerek nitel veri elde etmek mümkündür. Böylece elimizde sağlıklı, sayılabilen bir veri seti bulunacaktır.

Yararlanılacak yöntem ve yöntemlerin belirlenmesinde önemli olan bir durum da şöyledir, kullanılacak verinin basit veya karmaşık olma durumudur. Satış tahminleme üzerinden örnekleyerek açıklarsak; geçmiş bir dönem veya periyod avaraj satışları incelenir. Daha sonra ortamala satışıdaki değişkenlik incelenir. Burada hesaplamayı yapan kişi bir önceki gün ne sattığını ele alır, örneğin 50 adet, bugün yaptığı satış adedini ele alır örneğin 60 adet basitçe bu iki birbirini takip eden satışın ortalama değeri nedir, 55 adet, yarın ne satabilirim sorusunun cevabını maksimum 60 olarak belirleyebiliriz. Çünkü elimizdeki artış veya azalış ortalaması doğrusal olduğu için bir çıkarım yapmak kolay olacaktır. Dolayısıyla hata payımızda aynı oranda daha az olacaktır. Farklı bir örnek üzerinden gitmek gerekirse, önceki günün satışını 10 adet olarak ele alalım, bugünkü satış adedimiz ise 100 adet olur ise, yarın ki satış adedimizi tahmin ettiğimizde 55 adetlik bir ortalama değerine ulaşabiliriz. Ancak değişkenlik oranı yüksek olduğu için bunun tahmini ve hata oranı daha fazladır ve veri seti daha karmaşık bir yapıya sahiptir.

Printerlardan yani Türkçe adı ile yazıcılardan elde edilecek sayaç verileri sayısal yani nicel verilerdir. Bu verilerin nicel veriler olması dolayısıyla geleceğe ait tahminleme yapmak için en doğru tercih Regresyon olacaktır. Bu çalışma bağlamında yer alacak diğer bir parametre de ay parametresi olacaktır. Regresyon analizi yapabilmek için Haziran, Temmuz, Ağustos, X, Y, Z şeklinde çalışmaya dahil edilemeyeceğinden bu veriyi nitel değil, nicel veriye dönüştürmemiz gerekmektedir. Bu sebeple ay verisi 1,2,3,4,5,6 gibi adlandırılacak ve çalışmaya dahil edilecektir.

3.3.1 Tahmin Etkenleri

Genel manada bir firma yapacağı tahminleme için bu duruma etki eden bileşenlerle ilgili mutlaka bilgi sahibi olmalı ve incelemelidir. Bu etkenlere dair birkaç örnek aşağıda verilmiştir.

- i. Geçmiş baskı miktarı
- ii. Yazıcının baskı hacmi
- iii. Yazıcının teknik ömrü
- iv. Kullanıcı sayısı
- v. Yazıcının arıza durumu

3.4 Tahmin Performans Ölçme Teknik Ve Yöntemleri

E_t t süredeki öngörüde bulunan hata, t süresindeki baskı için öngörüde bulunan gerçek baskı değeri arasındaki farktır. Tahminleme: $E_r = F_t - D_t$ 'dir.

Bir averaj öngörü hata değeri negatif veya pozitif olma eğiliminde ise önyargı oluşturur. Matematiksel olarak bir öngörüde önyargı bulunmayacak ise formül $E(e_i) = 0$

şeklinde olmalıdır.

Çalışmada hatası bir tahmin mümkün olmayacaktır. Buna istinaden, çeşitli tahmin yöntemlerinin (tümü alt optimal) karşılaştırıldığında ve sonrasında muhtemel olarak birleştirildiği durumlar ortaya çıkacaktır. En iyi tahminlerde dahi gerçekleşen ve tahmin değerleri arasında ciddi farklar oluşabilir.

Örneğin, sıfır gürültülü beyaz gürültü işlemi için tahmin edilen en küçük kareler basitçe 0 (sıfır) olacaktır. Kuadratik kayıp altında daha iyi bir doğrusal tahmin yoktur.

Performans ölçümü genellikle aşağıda sıralanan dört ana hedefe ulaşmak için yapılır.

- i. Tahmin sürecinin gelişip gelişmediğini görmek için yapılır,
- ii. Belli tahminleme teknikleri veya araçlarıyla ilgili problemleri tespit etme,
- iii. Stok tutma kararlarına yardımcı olması amacıyla talep değişkenliğini tespit etme,
- iv. En iyi tahmini bulabilmek adına bireysel performansları takip ve tespit etme.

Performans Ölçümleri:

- i. Ortalama Mutlak Sapma (MAD)
- ii. Ortalama Mutlak Hata Yüzdesi (MAPE)
- iii. Ortalama Hatanın Karesi (MSE)
- iv. Kök Ortalama Kare Hatası (RMSE)

$$MAD = \frac{\sum_{t=1}^N |e_t|}{N} \quad MAPE = \frac{100 \left[\sum_{t=1}^N \frac{|e_t|}{D_t} \right]}{N} \quad MSE = \frac{\sum_{t=1}^N e_t^2}{N} \quad RMSE = \sqrt{MSE} = \sqrt{\frac{\sum_{t=1}^N e_t^2}{N}}$$

3.4.1 Ortalama Mutlak Sapma (MAD)

MAD yöntemi, bu genellikle tercih edilen bir yöntemdir, çünkü çerçeve almaya gerek yoktur. Formülü aşağıdaki gibi tanımlanır.

$$MAD = \frac{\sum_{t=1}^N |e_t|}{N}$$

3.4.2 Ortalama Mutlak Hata Yüzdesi (MAPE)

Ortalama bir mutlak hata yüzde hatasının formülü (MAPE), başka bir tahmin yönü ölçüsü, aşağıdaki gibi tanımlanmıştır.

MAPE 'yi MSE ve MAE 'den ayıran en önemli fark, büyük hatalara odaklanmamasıdır. MAPE 'deki bir değişiklik medyan mutlak hata yüzdesine (MdAPE)

neden olur. Bunu basitleştirmek için, mutlak yüzde, hataların medyan değeri olarak yorumlanabilir. Bu hatalarda çarpık bir dağıtım modelinin olması tercih edilir. Ancak, ortalama birkaç uç değer ile çarpılır ve hesaplama dahil edilir.

$$MAPE = \frac{100 \left[\sum_{t=1}^N \frac{|e_t|}{D_t} \right]}{N}$$

3.4.3 Hata Kareleri Ortalaması (MSE)

Ortalama hata karesi (MSE), tahmini hataları terim sayısına bölmek suretiyle hesaplanır. En küçük MSE değerine sahip model, en iyi model olarak kabul edilir.

MSE genellikle örnek kanıt özelliklerini özetlemek için tamamen açıklayıcı bir istatistiksel yöntem olarak kullanılır.

$$MSE = \frac{\sum_{t=1}^N e_t^2}{N}$$

3.4.4 Hata Kareleri Ortalamasının Kökü (RMSE)

Olumsuz hataların dengelenmesiyle olumsuz hatalarla baş etmenin bir başka yolu da kare yapmaktır. Negatif tahmin hatalarını kareleştirdiğimizde bu değerler otomatik olarak pozitif olacaktır. Bu kare değerlerin ortalaması alınır ve ortalamanın orjinal boyutuna yeniden ölçeklenmesi için karekök alınır. Bu yöntem Hata Karelerinin Ortalaması (RMSE) adı verilir. Farklı kaynaklarda, ortalama kare hatalarının ya da kök ortalama kare hatasının sapması da çağrılabilir.

$$RMSE = \sqrt{MSE} = \sqrt{\frac{\sum_{t=1}^N e_t^2}{N}}$$

3.5 İstatistiksel Yöntemlerle Talep Tahmini

3.5.1 Regresyon Analizi

Bu yöntem, örnek bağımlı değişken ve birden çok bağımsız değişkenin aralarında bulunan ilişkiyi matematiksel bir takım fonksiyonlar neticesinde bunları tanımlamasının sonucuna denmektedir. Ortaya çıkan fonksiyona ise regresyon denklemi denmektedir. Regresyon analizi yardımı ile bağımlı ile bağımsız arasındaki bağlantıyı ayarlayan farklı parametrik değerleri öngörülebilir kılmaktadır. Değişkenlerden bağımlı olanını doğrudan müdahalede bulunan bu faktör olan bağımlı olmayan değişkenin tahmin edilmesi, ilgili değişken dahilinde uygulanacak olan durumu ve hangi değişkenin önem kazandığının belirlenmesinde destek olmaktadır. [2].

Regresyon analizi yöntemi ile, hangi faktörlerin değiştiğini ve ilgilenilen değişkenin arttığını veya azaldığını belirlemek mümkündür. Yeterince tanımlayıcı ve öngörü yeteneği kuvvetli olan yöntemlerden olan bu algoritme geleceğe ait çeşitli öngörü ve kestirimlerde bulunabilir. Bu analiz yönteminde, belirli bir seyri olan ve bir düzen dahilinde olan geçmiş veriler kullanmak geliştirilebilir (formül) geliştirilebilir. Tahminlerin bağımlı olmayan değişkenlerinin faktörleri yüksek ölçüde olağandışı ise, tahmin hatası da yüksektir. Geçmiş veriler düzenli ve sürekli ise, değerlendirmenin tutarlılığı da yüksektir [73].

İki veya daha fazla değişken arasındaki ilişki doğrusal veya eğridir. Prensipler olarak basit doğrusal regresyon, birkaç doğrusal regresyon, üstel regresyon ve eğri regresyon denklemleri vardır. Bu denklemler matematiksel olarak şu şekilde ifade edilir.

Basit Doğrusal Regresyon :

$$Y = a + bX$$

(3.1) Çoklu Doğrusal Regresyon

$$Y = a + b_1X_1 + b_2X_2 + \dots + b_nX_n$$

(3.2)


Üssel Regresyon : $Y = a + b_1^x$

(3.3)

$$\text{Eğrisel Regresyon} : Y = a + b_1X + b_2X^2 + \dots + b_nX^n \quad (3.4)$$

Basit doğrusal regresyon, iki farklı değişkenler arasında bulunan ilişkinin doğrusal olduğu kabul edilirse, denklem " $Y = a + bX + e$ " olarak ifade edilebilir ve bağımsız değişkenin değeri konumuna yerleştirilir ve bir tahmine sahip olunmaktadır. Bu denklemde a ve b değeri en küçük kareler yöntemini bulabilmek için ("EKK") [1].

En küçük kareler yönteminde kullanılan matematiksel ifade, Şekil 3 'te gösterildiği gibi grafiksel olarak gösterilebilir.



Şekil 3 Regresyon Doğrusu

Şekil 4.5.1'deki regresyon çizgisinin grafiğinde gösterildiği gibi, bağımlı değişkenlerin değerleri ile gerçek değerler arasındaki farkın karelerinin toplamını minimumda tutmanın en iyi yolunu belirlemeye çalışıyoruz.

Durumu özetle örneklemek gerekirse, mevcut koşullarda bir otomobil satıcısı şirketin satışlarındaki büyümeyi ve bu oranı tahmin etmek istiyoruz. Satıştaki artış oranının mevcut ekonomideki büyüme oranının ortalama olarak 3 misli değerde olduğunu gösteren bir veri tablomuz bulunuyor. Bu yapıyı kullanarak otomobil firmasının

gelecek dönemlerdeki satışlarını ve mevcut ve geçmiş dönemdeki veriler ile tahminlemek mümkün olmaktadır.

Regresyon analizi yönteminin birçok faydasından söz etmek gerekirse, şu şekilde sıralabiliriz;

- i. Bağımlı değişken ve bağımsız değişken arasındaki ilişki seviyesini belirlemeye yardımcı olur.
- ii. Birden fazla bağımsız değişkenin, bağımlı değişkene etkisini ve bu duruma ait gücünü belirtmektedir.
- iii. Regresyon analizi ek olarak, fiyat değişkenliklerinin etkisi, promosyonel faaliyetleri adedi gibi farklı ölçek değerleriyle ölçülebilen değişkenlerin birbirine etkilerini tespitite yardımcı olmaktadır. Bu durum sayesinde, sektör araştırmacılarına, veri analizi yapan analistlere, veri bilimcilerine tahminleme modelleri oluşturmalarında fayda sağlamaktadır. Kullanılacak en iyi değişken veri kümesini ortadan kaldırmakta değerlendirme fırsatı sağlamaktadır.




Şekil 4 Regresyon Çizgi Grafiği

3.5.2 Korelasyon Yöntemi

Regresyon denklemi, bağımlı değişkenin bağımsız değişkenlerdeki değişikliklere karşı alacağı değerleri gösterir. Korelasyon, iki değişken arasındaki ilişkinin derecesini ifade eden ve çizginin uygunluğunu ölçen bir kavramdır. Başka bir deyişle, denklemin ilişkiyi ne derece tanımladığını gösterir. İlişki ne kadar güçlü olursa, öngörülen tahminlerin o kadar doğru olması beklenir [10].

Basit korelasyon, iki değişken arasındaki korelasyon katsayısı anlamına gelir. İki değişken arasındaki ilişkinin derecesini gösteren korelasyon katsayısı (r) ile gösterilir. Şekil 3.3, gerçek değerler ile tahmini değerler arasındaki korelasyonu gösteren eğrinin grafiğini göstermektedir. Korelasyon katsayısı, gözlem noktalarının regresyon çizgisine göre değişkenliğinin dolaylı bir ölçümüdür [1].



Şekil 5 Korelasyon Katsayısı Grafiği

Şekil 6 bağımlı olan değişkenin reel değerini korelasyon eğrisini göstermektedir. Korelasyonu kontrol eden 2 değişken arasındaki korelasyon değeri sürekli 1'den azdır.

Tablo 2 korelasyon katsayısının değerlerini yorumlamak için kullanılan kriterleri göstermektedir [14].

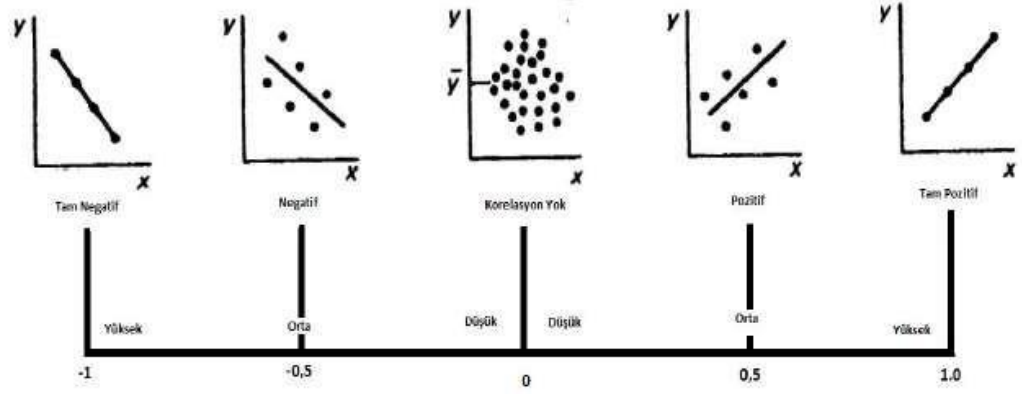
Tablo 2 Korelasyon katsayı

Korelasyon Katsayısı Deęeri	Yorumlamaları
0,90-1,00	Çok yüksek k.
0,70-0,90	Yüksek k.
0,40-0,70	Normal k.
0,20-0,40	Düşük korelasyon
0,00-0,20	Çok düşük korelasyon

Görüldüğü gibi, korelasyon katsayısı deęerleri yaklaşım 1'e yaklaşmakta, yüksek korelasyon meydana gelmektedir; 0 yaklaşımı düşük bir korelasyon ilişkisini gösterir. Korelasyon katsayısı (r) (-1.1) arasında herhangi bir deęeri alır. X deęerleri birlikte artarsa korelasyon deęeri pozitif olur; Eđer x azalırsa, negatif bir deęer alır. İki deęişken arasındaki ilişkinin olmaması durumunda, $r = 0$ 'dır. Korelasyon katsayısı deęere göre şu şekilde yorumlanır:

- Korelasyon katsayısı (r) 0'a yakınsa, ilişki zayıf,
- Korelasyon katsayısı (r), güçlü pozitif, +
- Korelasyon katsayısı (r);

Korelasyon katsayısının imleci çoęunlukla b katsayı deęeri ile aynıdır. Regresyon çizgisinin yönünün negatif olması durumunda korelasyon çarpanının deęerinin negatif olacağını göstermektedir [10]. Şekil 3.4, korelasyon katsayılarının deęerlerini ve yorumlarını göstermektedir.



Şekil 6 Korelasyon Katsayı Yorumlama

Şekil 6 'da gösterildiği gibi, korelasyon değeri arttıkça ve grafiklerdeki dağılım düz bir çizgi etrafında yoğunlaştıkça korelasyon değeri 1'e yükselir. Aksine, dağıtım 0'a yaklaştıkça yayılır.

3.5.2 Zaman Serileri Analizi Kaynaklı Talep Tahmin Yöntemleri


Bu analiz yöntemi, bir işletmenin geçmiş satışlarını incelemek ve bu satışlarla ilgili belirli bir eğilim olup olmadığını tespit etmek ve gelecek için talep tahminleri yapmaktır [1]. Zaman serileri analizi tarihsel verilere dayanmaktadır. Amaç, tarihsel verilere bakarak geleceği tahmin etmektir [10]. Geçmiş verileri düzenli aralıklarla toplayarak elde edilen istatistiksel veridir [2]. Zaman serileri değişkene düzenli aralıklarla yapılan bir dizi gözlemdir [11].

Zaman serileri analizi yapılırken belirli dönemlerde gözlemlenen talep bilgileri bir ölçekte listelenir ve üretilen talep hattının belirli bir düzen gösterip göstermediği incelenir. Bu gözlem sonucunda talebin sabit olduğu, bir eğilim gösterdiği veya mevsimsel / mevsimsel değişiklikler gösterdiği veya hepsinin karışık bir şekilde dağıldığı görülmektedir.

Zaman serisi analistleri, gözlemlenen talep verilerini belirli zamanlarda yerleştirerek bir zaman ölçeği oluşturur. Bu veri noktalarını inceleyerek, bu noktaların zaman içinde sabit bir seyir izleyip izlemeyeceklerini belirlemeye çalışırlar [17]. Zaman serilerinde, ortalama talep seviyesinde uzun vadeli bir artış veya düşüş varsa, bir trendden

söz edilebilir. Eğilim; yükselen, azalan, doğrusal veya doğrusal olmayan olabilirler. Talep modellerinde uzun vadeli bir eğilim tespit edildiğinde, yöneticiler bu sonuca dayanan talep beklentilerine sahip olabilirler [10].

Şekil 8 zamanla değişebilen çeşitli talep modellerini göstermektedir.



Şekil 7 Zaman ayraçlı talep düzeni

Şekil 7 'de, zaman serisi analizi, doğrusal eğilim, sezonsal/mevsimsel değişim eğrisi ve sabit talep modellerine dayanan talep tahminlerindeki eğilimler grafik üzerinde gösterilmektedir.

Zaman Serisi Analiz Yöntemleri uygulanırken izlenmesi gereken adımlar aşağıdaki gibidir [17]:

- i. İlgili zaman serisi, tahmin yönteminin değerlendirilip yürütülebilmesi için iki eşit parçaya bölünmüştür.
- ii. Tahmin yöntemi olası yöntemlerden seçilmiştir.
- iii. İlk veri seti tahmin yöntemini başlatın.
- iv. Modelin parçalarını hesaplamak için kullanılmayan veriler, etkinin nasıl tahmin edildiğini görmek için test setine de uygulanır. Tahmin hataları, her tahminden sonra hesaplanır. Bu adım, başlangıç işlemlerinin modeldeki parametre değerlerini barındıracak şekilde düzenlenmesini gerektirir.
- v. Tahmin yönteminin farklı veri örnekleri için uygunluğu değerlendirilir.

Zaman serisi analizine dayanan en çok kullanılan tahmin yöntemlerinden bazıları; Basit Ortalama Yöntemi, Son Talep Yöntemi, Hareketli Ortalama Yöntemi, Üstel Düzeltme Yöntemi ve Box-Jenkins yöntemleridir.

3.5.2.1 Basit Ortalamalar Yöntemi

Basit ortalama, art arda gözlem sayısı ile bölünen art arda verinin toplamıdır. Bu yöntem, geçmiş veriler genellikle yukarı veya aşağıya doğru eğilim göstermediğinde veya gelecekte önemli bir değişiklik beklenmediğinde öngörücü çalışmalarda kullanılabilir. Bununla birlikte, ilerleyen dönemlerde yukarı veya aşağı doğru bir eğilim gözlenirse, talep öngörülen talepten aynı yönde sapmalar gösterir [15].

3.5.2.2 Son Dönem Talep Yönetimi

Son dönemdeki talepte, önceki döneme ait talep, gelecekteki talebin tahmini olarak kullanılır. Bu yöntem uzun hesaplamalar gerektirmez. Arka plan verileri, sürekli ve ortalama bir değer etrafında hafifçe değişme eğilimindeyse tercih edilir [9].

3.5.2.3 Hareketli Ortalamalar Yöntemi

Talep edilen mevsimsel dalgalanmaları inceleyerek bu dalgalanmaların talebe etkisini belirlemek için kullanılan bir yöntem olarak bilinmektedir. Satış tahminlerini önceki dönemlerde inceleyerek ve zaman eğilimine göre satış eğiliminden yararlanarak, talep tahminleri gelecek dönemlerde yapılabilir.

Hareketli ortalamalar yönteminin en belirgin özelliği, mevsimsel etkilerin talebe olan etkisinin önemli olması ve eskilerinin tarihsel verileri dikkate almamasıdır. Hareketli ortalamalara dayanan tahminler, aylık satışlar önceki veya son aylardan etkilenirse iyi sonuçlar verir [9].

Hareketli ortalama yöntemine göre, 3, 4, 6 ve 12 aylık satış ortalamalarına göre değerlendirme yapılabilir [14]. Hareketli ortalama yöntemi, en eski değeri tekrar ederek ve yeni değeri ekleyerek, belirli sayıda periyodun değerlerini tekrarlayarak elde edilir. Hareketli ortalamalar, genel veri sırasını korurken veri dalgalanmalarını düzeltebilir.

Bununla birlikte, bir tahmin denklemi oluşturmazlar ve veri serisinin son değerlerinin bir tahminini sunmazlar [11].

Yeni bilgi geldiğinde, ortalamalara hareketli ortalamalar denir. En eski değer daima gerçek talebin ortalama değeri ile geçmiş dönem için yeni değer eklenerek elde edilir. Sonuç, önümüzdeki dönem için öngörü değeri olarak kullanılır. Tepki oranı, hareketli ortalama periyodların sayısı ve her bir periyodun ağırlığı ile kontrol edilir. Örneğin, üç aylık ortalama hareketli Temmuz tahmini, Nisan, Mayıs ve Haziran aylarında yapılan satışların ortalamasıdır [10].

Hareketli ortalamalar geçmişe göre geçmişe göre daha fazla ağırlık verir ve buna dayanarak, satış tahmini sadece bir süre içindir. Örneğin, son döneme ait tarihsel verilerin üç, dört veya beşi eklenmiştir. Bu verinin ortalaması daha sonra bir sonraki satış tutarı olarak kabul edilir [1]. Hareketli ortalama yöntemi, talebin artış eğilimi gösterdiği düşük bir tahmindir. Talep azalan bir eğilim gösterdiğinde, yüksek bir tahmin gösterir.

3.5.2.4 Ağırlıklı Ortalama Yöntemi

Bu yöntem, belirli dönem verileri (en güncel tarihsel veriler) gelecek dönemler hakkında net bir fikir verdiğinde kullanılabilir. Ağırlıklı ortalama yönteminin dayandığı ana fikir, tarihsel bilginin ortalama üzerinde eşit etkiye sahip olmadığı yönündedir. Bu nedenle, eğilim koşulunun ve diğer faktörlerin etkisi ortalama olarak azaltılmalıdır. Bu yöntemde, ilk dönemden beri geçen tüm dönemler dikkate alınır [9].

3.5.2.5 Ağırlıklı Hareketli Ortalama Yöntemi

Ağırlıklı hareketli ortalama yönteminde, ağırlıklar ağırlıklı ortalama yönteminde olduğu gibi ağırlıklandırılır. Ancak, geçmişin tüm değerleri dikkate alınmaz. Bu yöntemde, tahmin edilirken belirli sayıda en yakın dönem değeri dikkate alınır. Hesaplama sırasında, daha yeni süreler daha fazla ağırlık verilir. Dikkate alınacak sürelerin sayısı ve ağırlıklar değiştikçe, tahmin değerleri de değişmektedir [9].

3.5.2.6 Üssel Düzeltme Yöntemi

Üstel düzeltme yöntemi, ağırlıklı ortalama sistemini dikkate alan bir tahmin yöntemidir. Bir önceki döneme ait verilerin eşit şekilde ağırlıklandırıldığı basit hareketli

ortalama yöntemine benzer. Farklı ağırlıkların önceki döneme ait verilerle uyuşmadığı bir yöntem topluluğudur. Üstel terimi, belirtilen ağırlıkların, verilerin yaşının artmasıyla birlikte üssel olarak azaldığı anlamına gelir. Başka bir deyişle, tahminde kullanılan geçmiş verilerin yüksek üssel değerlere sahip olması, eski verilere düşük üssel değerlerin verilmesine yol açmıştır [2].

Üstel düzeltme, hareketli ortalamalardaki en son geçmiş verilere daha fazla ağırlık vermek için üssel olarak tarihsel verileri genişleten bir tahmin yöntemidir. Belirtilen ağırlıklar üstel fonksiyon tarafından ifade edilebilecek bir seriyi temsil ettiğinden, istatistiki verilerin depolanması zorluğundan kaçınılır. Üstel düzeltmenin avantajı, eski veriler olmadan kolayca hesaplanabilmesidir [9].

Metotta kullanılan α düzeltme katsayısı 0 ile 1 arasında değerler alabilir. Bir katsayı kullanılarak, gerekli veri miktarı önemli ölçüde azaltılır. Hareketli ortalama yönteminde olduğu gibi, ortalama dönem sayısı kadar veri gerekmez.

$\alpha = 1$ ve düzeltme katsayısının (α) olduğu durumda, yöntem son dönem talebinin işlemine dönüştürülür. $\alpha = 0$ seçilirse, ilk dönem için talep, sonraki dönemlere aktarılır, bu anlamsızdır. α katsayısının 0,2 ile 0,8 arasında seçilmesi önerilir. Daha yüksek α değerleri, değişken talep seviyelerini tahmin etmek için kullanılır ve genellikle gerçek talep değerlerinin ağırlıklandırılmasını gerektirir. Bu durumda, son dönem verilerinin ve dolayısıyla rasgele faktörlerin etkisinin tahmin üzerinde büyük bir etkisi vardır. Düşük α değerleri, geçmişe ait ortalama değer kullanımasına izin vererek daha kararlı bir yapıya sahip kayıtları tahmin etmek için kullanılır. Bu durumda, tarihsel verilerin tahmin üzerindeki etkisi daha büyüktür ve rastgele değişkenlerin etkisi azalır [9].

3.5.2.7 Jenkins Yöntemi

Konu yöntem bir değişkeni olan bir tür yöntemdir ve uzun olmayan vadede tahminlerde çok başarılıdır. Box-Jenkins yönteminin uygulandığı serinin, eşit zaman aralıklarında elde edilen kesikli ve durağan bir gözlem değerleri dizisi olduğu bu yöntemin değerli varsayımdır. Tekniğin amacı, minimum sayıda parametre ile uygun modeller elde etmektir. Box-Jenkins'ten önce kullanılan Hareketli Ortalama ve Üstel Düzeltme Teknikleri'nde, tahmin değerleri bilgisayar programına müdahale etmeden

otomatik olarak elde edilir. Diğer tekniklere göre de anlaşılması çok karmaşık ve zordur. Box-Jenkins yöntemi, çalışılan serinin durağan olduğu durumlarda, mevsimsel etkileri olup olmadığına göre farklı öngörücü modeller geliştirme yeteneğine sahiptir. Öte yandan, Box-Jenkins yöntemi aynı zamanda zaman serileri boyunca filtreleme yönetimi olarak da adlandırılmaktadır [2].

3.5.2.8 Regresif Hareketli Ortalamalar (AR-MA) Yöntemi

Zaman serilerinin modellenmesinde esneklik sağlamak ve minimum parametre prensibi sayısına ulaşmak için, bazen otoregressive ve hareketli ortalama parametrelerin elde edilmesi bazen daha avantajlıdır. Bu fikir otoregressif hareketli ortalamaların yöntemini ortaya koydu. Otoregressif hareketli ortalama yönteminde, rastgele bir zaman serisinin her periyodu için elde edilen gözlem değerleri, belirli sayıda gözlem değerinin lineer bir kombinasyonu ve o periottan önceki bir hata terimi olarak ifade edilir.

Otoregressif (AR) işlem, verilerin zaman içinde değişmeyeceği varsayımına dayanır. Örneğin, ayda 100 birim varsa, bu farkı karşılamak için ayda 100 birim değiştirilecektir. Daha fazla veya daha az satış yapılmazsa, süreç etkilenmez. Bu otoregressive bir süreçtir. Hareketli Ortalama (MA) işlemi, güncel hata terimini etkileyen seri gecikmeli hata terimi olarak tanımlanır [16].

3.5.2.9 Otoregressif Bütünleşik Hareketli Ortalamalar (ARIMA) Yöntemi

Otoregressif Entegre Hareketli Ortalamalar modeli, zaman serilerine dayanan sayısal bir modeldir; tek veya çok değişkenli olabilir. Talep tahmini çalışmalarında, tek değişkenli Otoregressif Entegre Hareketli Ortalamalar yöntemi çoğunlukla kullanılmaktadır [8]. Modelin ana işlevi otoregressive süreçleri içermesidir. Başka bir deyişle, tarihsel verileri kullanarak, gelecekle ilgili istatistiksel tahminlerde bulunabileceği, süreçleri birleştirebileceği ve tüm hareketli ortalama işlemlerini bir araya getirebileceği bilinmektedir [6].

Box ve Jenkins, iki modeli birleştirerek Otoregressif Entegre Hareketli Ortalamalar modelini geliştirdi. Bu yaklaşım, zaman serilerinin durağan olduğu varsayımına dayanmaktadır. Zaman serilerinin statik olmadığı gerçeği, belli bir eğilim

içerdikleri anlamına gelir. Zaman serileri durağan değilse, zaman serisini bir veya daha fazla zaman farkı ile dengeleyerek otoregresif bir Entegre Hareketli Ortalamalar yapısı oluşturulabilir [16].

3.6 Simülasyon (Benzetim) Yöntemiyle Talep Tahmini

Simülasyon terimi, genellikle gerçek sistemin işlevli bir modelidir. Simülasyon, gerçek sistemi arayan bir analiz yöntemi olarak da düşünülebilir. Önceden belirlenmiş bir simülasyon modeli, işleme başladığı andan başlayarak asıl sisteme biraz daha yakındır [1].

Simülasyon gerçeği en geniş anlamıyla sunmak demektir. Bu anlamda, simülasyon bir simülasyon sürecidir. Simülasyon, fiili olayların sözlü, resmi veya sembolik olarak gösterimidir.

Simülasyon yönteminde, dahili değişkenlerin olası değişiklikleri, harici değişkenlerin verilerine göre hesaplanır. Kısacası, gelecek simülasyonla tahmin ediliyor.

Simülasyon, rekabetin günden güne arttığı ve piyasa koşullarının zorlaştığı karmaşık süreçlerin ve sistemlerin tasarımında en güçlü analiz araçlarından biri olarak görülmektedir. Çünkü simülasyon; Sistemde oluşabilecek risklere karşı sisteme yeterli esneklik sağlamak için sistemin işletilmesinden sorumlu kişiler üzerinde çalışma imkanı sağlar [1], [18].

Simülasyon, özellikle analitik ve sayısal çözüm yöntemleri uygulanmadığında veya pratik olmadığında kullanılır. Varsayımları formüle etmek mümkünse ve sistem mevcutsa, önce analitik modelleri test etmek gerekir. Simülasyon modelleri ile analitik modeller arasında karma modeller bulunmaktadır. Analitik modeller cevap vermezse, karışık modeller uygulanır ve sonuç alınmazsa simülasyon modeli uygulanır. Çoğu karmaşık sistem için, analitik yöntemler ve karma yöntemler çok pahalı ve sistem için uygun olmayan uzun yöntemlerdir. Simülasyon yöntemleri ve zaman içindeki sistem davranışı; Farklı koşullar altında, sistem elemanlarının davranışı incelenmekte ve elemanlar arasındaki ilişki anlaşılmaktadır [1], [13], [19].

Günümüzde kullanılan simülasyon, işletme yönetiminde karşılaşılan sorunları çözmek için bir bilgisayarı kullanarak matematiksel bir model aracılığıyla gerçek bir

sistemin temsil edilmesini sađlayan bir tekniktir. Bilgisayar alanındaki teknolojik geliřmeler ve deđiřimler nedeniyle simülasyon tekniđi hızla geliřmiřtir. Bu durum nedeniyle, özellikle operasyon alanlarında, birçok alanda uygulama imkânı buldu. Simülasyonun diđer kullanımları; ekonomi, pazar arařtırması, talep tahminleri, eđitim, politika, sosyal bilimler, davranıř bilimleri, řehir planlama ve savunma vb. alanlar. Simülasyon tekniđi de talep tahminlerinde yaygın olarak kullanılmaktadır.

3.7 Yapay Sinir Ađları Yöntemiyle Tahminleme

Yapay sinir ađlarının yapısının detaylı ađıklamalarından ve insan sezgisini anlama ve taklit etme yeteneđinden anlařılacađı gibi günümüzde řirketler, yapay sinir ađı yöntemini, neredeyse tüm karar alma süreçlerinde kritik olan talep tahmin çalıřmalarında kullanmaktadır.

3.7.1 Yađay Sinir Ađları

Yapay Sinir Ađları (Yapay Sinir Ađları - YSA), her biri bilgi ve bilgi gönderen, birbirlerine paralel çalıřan insan beyninin ilkelerine ilham vererek geliřtirilen bir organizasyondan oluřur. Problem çözmek için kullanılan iř elemanları (yapay sinir hücreleri) bir ađda birbirine bađlanır. Hücreler arasındaki bilgi akıřı, bađlantı deđerleri ve iliřkilerle temsil edilir. Bađlantı deđerleri kullanılarak, sistemin öđrenme yeteneđi ve akıllı davranıřı elde edilir [14].

İnsan beyninin özelliklerini taşıyan yapay sinir ađları, yeni bilgi edinme ve bilgisayar sistemlerini keřfetme gibi yeni bilgileri edinmenin yollarını öđrenmek, herhangi bir yardım almadan otomatik olarak çalıřacak řekilde geliřtirilmiřtir. Yapay sinir ađları, programlama çok zor ve uyarlanabilir hesaplama için geliřtirilemeyen olaylarla ilgilenen bir bilgisayar bilimi olduđu söylenebilir [20].

Yapay sinir ađları, insan beyninin iřlevsel özelliklerini taklit eden öđrenme, birleřtirme, sınıflandırma, genelleme, belirleme özellikleri ve optimizasyon gibi konularda kullanılır. Örneklere gelen bilgilerle kendi deneyimlerinizi oluřturun; bu nedenle benzer konularda benzer kararlar alırlar. Bilim adamları beynin nörofiziksel yapısını incelemiř, insan beyninin özelliklerinden ilham almıř ve matematiksel modeli

çizmeye çalışmışlardır. Bu nedenle, beynin fiziksel bileşenlerinin beynin tüm davranışlarını tam olarak modellemek için uygun şekilde modellenmesi gerektiği fikrine dayanarak birçok yapay ve ağ hücre modeli geliştirdiler. Sonuç olarak, Yapay Sinir Ağları denilen ve normal bilgisayarlardan farklı işlemler gerçekleştirme yöntemi olan farklı bir bilimsel alan ortaya çıkmıştır.

Yapay sinir ağlarına sahip ilk hesaplama modelleri, 1943'te 1940'ların başında yayınlanan Culloch ve Pitts'in makaleleriyle başladı. Bu alandaki ilk çalışmalar, beyin hücrelerinin işlevlerini ve birbirleriyle iletişim yollarını göstermeyi amaçlamaktadır. Ardından, 1954'te, Farley ve Clark bir ağdaki uyarılara cevap verdi. Uyarılara uyum sağlamak için bir model oluşturuldu. İlk sinir bilgisayarı 1960 yılında piyasaya sürüldü. 1963 yılında, basit modellerin ilk eksikliklerine dikkat çekildi ve 1970'lerde ve 1980'lerde başarılı sonuçlar elde edildi ve termodinamiğin teorik yapıları doğrusal olmayan ağların gelişmesine kadar ertelendi. 1985 yapay sinir ağlarının yaygın olarak tanındığı ve yoğun araştırmalara başladığı yıl olarak bilinir [1], [4], [8].

Yapay sinir ağları ve insan beyninin bilişsel öğrenme süreci, biyolojik nöron hücresinin yapısını ve öğrenme özelliklerini uyararak geliştirilen çeşitli işleme elemanlarından oluşan bir bilgisayar işleme ve bilgisayar sistemi olarak tanımlanabilir [12].

Yapay sinir ağları biyolojik sinir sistemini taklit etmeye çalışan insanlarda basit bir sinir hücresi modelini simüle eder; öğrenme, ezberleme ve öğrendiklerini genelleştirme gibi insani özellikleri taklit edebilen bir sistemdir. Paralel çalışma özellikleri nedeniyle çok kısa sürede sonuç üretebilirler, bu yüzden gerçek zamanlı problemleri çözmeye çok yararlı sonuçlar verirler [7], [21], [22], [23].

Literatürde bazen nörobilgisayarlar, iletişim ağları ve dağıtılmış paralel işlemciler gibi isimler denir [24].

Yapay sinir ağları, tahmin, modelleme, araç rotalama, sokak satıcıları problemi, gruplandırma ve operasyonel araştırma alanlarına dahil edilen sınıflandırma gibi birçok alandaki problemleri çözmek için tercih edilen yöntemdir. Yapay zeka ve beyin modellemesi alanlarında geliştirilen regresyon ve benzeri yöntemler gibi bağımlı ve bağımsız değişkenler arasındaki ilişkiyi inceleyen bir fonksiyon tahmin aracıdır. Yapay sinir ağları ve istatistiksel yöntemler arasındaki temel fark, sinir ağlarının istatistiksel dağılım veya veri özellikleri hakkında varsayımlarda bulunmamasıdır. Bu doğrusal

olmayan bir tahmin yöntemi olduğundan, literatürde karmaşık veri modellemesinden daha olumlu sonuçlar üretmek için de önemlidir [95].

Yapay sinir ağları, ayarlanabilir ağırlıklar ile bağlanmış birkaç basit işlem biriminden oluşur. Geleneksel model tabanlı yöntemlerin aksine, değişkenler arasındaki ilişkileri bilmek ya da anlamak zordur, ancak bu ilişkileri veriden türetebilir ve örneklerden öğrenebilirler. Yapay sinir ağları, bir veri setindeki veri setini genelleştirme, anlama, sınıflandırma ve uyarılma yeteneğine sahip alternatif hesaplama araçlarıdır [96]. Yapay sinir ağları tipik bir akıllı öğrenme paradigması türüdür. Özellikle uygulamalı çalışmalarda çok çeşitli uygulamalar vardır [9].

Yapay sinir ağı modelinin gücü, yapay nöronların işbirliğinden kaynaklanmaktadır. Bu sistemlerin en önemli avantajları öğrenme ve çevresel değişimlere uyum sağlama yetenekleridir. Yapay sinir ağları problemi tanımlamak ve matematiksel bir model inşa ederek geleceği tahmin etmek için geçmiş verileri kullanır [8].

3.7.2 Yapay Sinir Ağlarının Özellikleri

Yapay sinir ağlarının özellikleri kullanılan ağ modeline ve kullanılan algoritmalara göre değişir, ancak genel olarak şu şekilde sıralanabilir [20], [24]:

- Yapay sinir ağları makine öğrenmesini gerçekleştirir. Temel işlevi, bilgisayarların öğrenmesini sağlamaktır. Olayları öğrenerek benzer olaylar karşısında benzer kararlar almaya çalışırlar.
- Programların çalışma stili bilinen programlama yöntemleriyle aynı değildir.
- Yapay sinir ağları örneklerini kullanmayı öğrenir.
- Yapay sinir ağlarını güvenli bir şekilde çalıştırmak için performansları için eğitilmeleri ve test edilmeleri gerekir.
- Yapay sinir ağlarında, bilgi ağ bağlantılarının değerleri ile ölçülür ve bağlantılarda saklanır.

• Benzeri görülmemiş örnekler hakkında bilgi üretebilirler. Ağ kendisine gösterilen örneklerin genellemelerini yapabilir ve görmediği örnekler hakkında bilgi verebilir.

- Algılamaya yönelik olaylarda kullanılabilirler.
- Şekil ilişkilendirme ve sınıflandırma yapabilir.
- Desen tamamlama işlemi gerçekleştirir.
- Kendi kendine organize etme ve öğrenme yeteneği.

• Eksik bilgi ile çalışabilirler. Yapay sinir ağları, eğitimden sonra bile, yeni örnekler eksik bilgilerle bile sonuç üretebilirken, geleneksel sistemler eksik bilgilerle çalışamaz.

• Hata toleransı var. Eksik bilgi ile çalışma yetenekleri, hatalara toleranslı olmalarını sağlar. Ağ hücrelerinin bazıları bozulursa ve çalışmazsa, ağ çalışmaya devam eder. Geleneksel bilgisayarlar genellikle tam veri gerektirir.

- Kademeli bozulma gösterirler.

• Hafıza dağıttılar. Yapay sinir ağlarındaki bilgiler ağ üzerinden yayılır. Yani, tüm ağ tüm olayı karakterize eder.

• Sadece sayısal bilgilerle çalışır; Sembolik ifadelerle belirtilen bilgiler sayısal değerlere çevrilmelidir.

- Belirsiz ve eksik bilgileri işleyebilirler.

• Yapay sinir ağlarında, bilgi ağ bağlantılarının değerleri ile ölçülür ve bağlantılarda saklanır.

• Benzeri görülmemiş örnekler hakkında bilgi üretebilirler. Ağ kendisine gösterilen örneklerin genellemelerini yapabilir ve görmediği örnekler hakkında bilgi verebilir.

- Tespit olaylarında kullanılabilirler.
- Şekil ilişkilendirme ve sınıflandırma yapabilir.
- Desen tamamlama işlemi gerçekleştirir.

- Kendi kendine organize etme ve öğrenme yeteneği.
- Eksik bilgi ile çalışabilirler. Yapay sinir ağları, eğitimden sonra bile, yeni örnekler eksik bilgilerle bile sonuç üretebilirken, geleneksel sistemler eksik bilgilerle çalışamaz.
- Hata toleransı var. Eksik bilgi ile çalışma yetenekleri, hatalara toleranslı olmalarını sağlar. Ağ hücrelerinin bazıları bozulursa ve çalışmazsa, ağ çalışmaya devam eder. Geleneksel bilgisayarlar genellikle tam veri gerektirir.
- Kademeli bozulma gösterirler.
- Hafıza dağıttılar. Yapay sinir ağlarındaki bilgiler ağ üzerinden yayılır. Yani, tüm ağ tüm olayı karakterize eder.
- Sadece sayısal bilgilerle çalışır; Sembolik ifadelerle belirtilen bilgiler sayısal değerlere çevrilmelidir.
- Belirsiz ve eksik bilgileri işleyebilirler.
- Hata Toleransı: Yapay sinir ağlarındaki paralel yapı, ağın doğru bilgileri üretme yeteneğini önemli ölçüde etkilemez, çünkü bazı bağlantılar veya hücreler etkisiz hale gelir, çünkü ağ tarafından sağlanan bilgiler tüm bağlantılara yayılabilir. Bununla birlikte, çok sayıda hücrenin çeşitli yollarla bağlanmasıyla oluşturulduğundan, paralel bir yapıya sahiptir ve ağın bilgileri ağdaki tüm bağlantılar üzerine dağıtılmaktadır. Bu nedenle, bazı bağlantıların hücrelerinin ve hatta bazı eğitilmiş sinir ağlarının verimsizliği ağın doğru bilgisini önemli ölçüde etkilemez. Bu nedenle, hata ayıklama yetenekleri geleneksel yöntemlerle karşılaştırıldığında son derece yüksektir.
- Genelleme: Yapay sinir ağları, örnekler tarafından görülmeyen örnekler hakkında bilgi verebilir. Eğitilmesi gereken olayları öğrenmek için yapay sinir ağları tanımlanmalıdır. Örnekleri kullanarak, ilgili olay hakkında genelleme yeteneği kazanılmış ve ağ eğitilmiştir. Yapay sinir ağını, gerçek örnek veriler olmadan eğitmek mümkün değildir. Ağı eğitirken kullanılan örneklerin olayı temsil etmesi önemlidir. Olayın tüm yönleriyle birlikte ağa örnekler gösteriliyorsa, ağ sorunsuz çalışacaktır.

- Sınıf Bozulma: Ağlar eksik ve sorunla karşılaştığında hemen bozulmazlar. Hata toleranslarına sahip olduklarından, yavaş yavaş bozulurlar.

- Uyarlanabilirlik: Ağırlıkların yapay sinir ağlarında yeniden yapılandırılabilmesi gerçeği, problemdeki değişikliklere dayanarak belirli bir sorunu çözmek için eğitilmiş bir sinir ağının oluşturulmasını ve uyarlanmasını sağlar. Yapay sinir ağları ağırlıklarını problemdeki değişikliklere göre ayarlar. Yani, belirli bir problemi çözmek için eğitilmiş yapay sinir ağları, problemdeki değişikliklere göre yeniden eğitilebilir ve değişiklikler sürekli ise, gerçek zamanlı olarak eğitime devam edilebilir. Bu özellik yapay sinir ağları, uyarlanabilir örnek tanıma, sinyal işleme, sistem tanılama ve inceleme gibi alanlarda etkili bir şekilde kullanılır.

- Donanım ve Hız: Yapay sinir ağları, VLSI (Büyük Ölçekli Entegre Devre) teknolojisine paralel yapıları nedeniyle uygulanabilir. Bu özellik yapay sinir ağlarının hızlı bilgileri işlemesini ve gerçek zamanlı uygulamalarda tercih edilmesini sağlar.

- Analiz ve tasarım kolaylığı: Yapay sinir ağlarının temel işlem elemanı olan hücrenin yapısı ve modeli, tüm yapay sinir ağ yapılarında yaklaşık olarak aynıdır. Bu nedenle, yapay sinir ağlarının çeşitli uygulamalardaki yapıları bu standart yapı hücrelerinden oluşmaktadır. Bu nedenle, çeşitli uygulamalarda kullanılan yapay sinir ağları benzer öğrenme algoritmaları ve teorileri kullanılabilir. Bir sinir ağı, katmanlar halinde düzenlenmiş bir sinir ağı olarak düşünülebilir. Ağın en düşük katmanı giriş seviyesidir ve en üst katmanın çıkış seviyesi vardır. Her seviye daha yüksek seviyelerde birbiriyle ilişkilidir. Bir sinir ağı oluşturmak için gerekli bileşenler; Ağ mimarisi, aktivasyon fonksiyonları, maliyet fonksiyonu (tahminin doğruluğu), eğitim algoritmasının bileşenleri [21], [25].

3.7.3 Yapay Sinir Ağları Geçmişi

Yapay sinir ağlarının tarihi, insanların nörobiyolojiye ilgileri ve bilgisayar bilimlerine uygulanmaları ile başlar. Bu çalışmalar şu şekilde özetlenebilir [16], [20]:

1890: İlk yayını insan beyninin yapısı ve fonksiyonları üzerine yazın.

1911: İnsan beyninin bileşenlerinin sinir hücrelerinden oluştuğu fikrinin benimsenmesi

1943: Yapay sinir hücrelerine dayanan hesaplama teorisine giriş: Warren McCulloch / Walter, "sinir aktivitesinde rasyonel bir düşünce hesaplaması" teorisini önerdi.

1949: Biyolojik olarak mümkün öğrenme prosedürlerinin bilgisayar gelişimi: Hebb kuralı.

1956-1962: Adaline ve Windrow algoritması geliştirme.

1957-1962: tek katmanlı bir sensörün (Perceptron) geliştirilmesi.

1965: İlk makine öğrenme kitabını yazdı.

1967-1969: bazı ileri öğrenme algoritmalarının geliştirilmesi: Grosberg'in öğrenme algoritması.

1969: Tek katmanlı sensörlerin problem çözemediğini gösterin.

1969-1972: İlişkisel bellek çalışmaları: Kohonen ve Anderson tarafından yapılan çalışmalar.

1969-1972: Doğrusal korelatörlerin gelişimi.

1972: korelasyon hafızası ve kayıt numarasının geliştirilmesi.

1974: Geri Yayılım modelinin geliştirilmesi (çok katmanlı sensörlerle ilgili erken çalışmalar).

Eğitici olmayan öğrenmenin gelişimi:

1978: ART modelinin geliştirilmesi.

1982: Kohonen SOM modelinin öğrenilmesi ve geliştirilmesi.

1982: Hopfield ağlarının geliştirilmesi.

1982: Çok katmanlı sensörlerin geliştirilmesi.

1984 Boltzman makinesinin geliştirilmesi.

1985: Genelleştirilmiş Delta öğrenme kuralı ile çok katmanlı sensörlerin geliştirilmesi.

1988: RBF modelinin geliştirilmesi.

1988: PNN modelinin geliştirilmesi.

1991: GRNN modelinin geliştirilmesi

1991'den beri birçok araştırma ve uygulama geliştirilmiştir.

3.7.4 Yapay Sinir Ağları Yönteminin Farklı Yöntemlerle Karşılaştırılması

Yapay sinir ağları ile kestirim yöntemi, kullanılan diğer yöntemlerden çok farklı bir terminolojiye sahiptir. Örneğin, sinir ağları terminolojisinde ağ ağ-ağı terimi, ağ modelinin yerine kullanılır. "Kullanılmadan parametresi yerine ağırlıklar" terimi, "ağın çalışması" hakkında bilgi vermek için, "tahmini parametreler" terimi hakkında konuşmak yerine, "tahmini parametreler" terimi anlamına gelir.

Yapay sinir ağlarının bazı özellikleri, problemin yapısına ve kullanılan sinir ağının modeline bağlı olarak, geleneksel bilgi işlem yöntemlerinden ayrılmış özelliklerden bazıları **Tablo X** 'de gösterilmektedir.

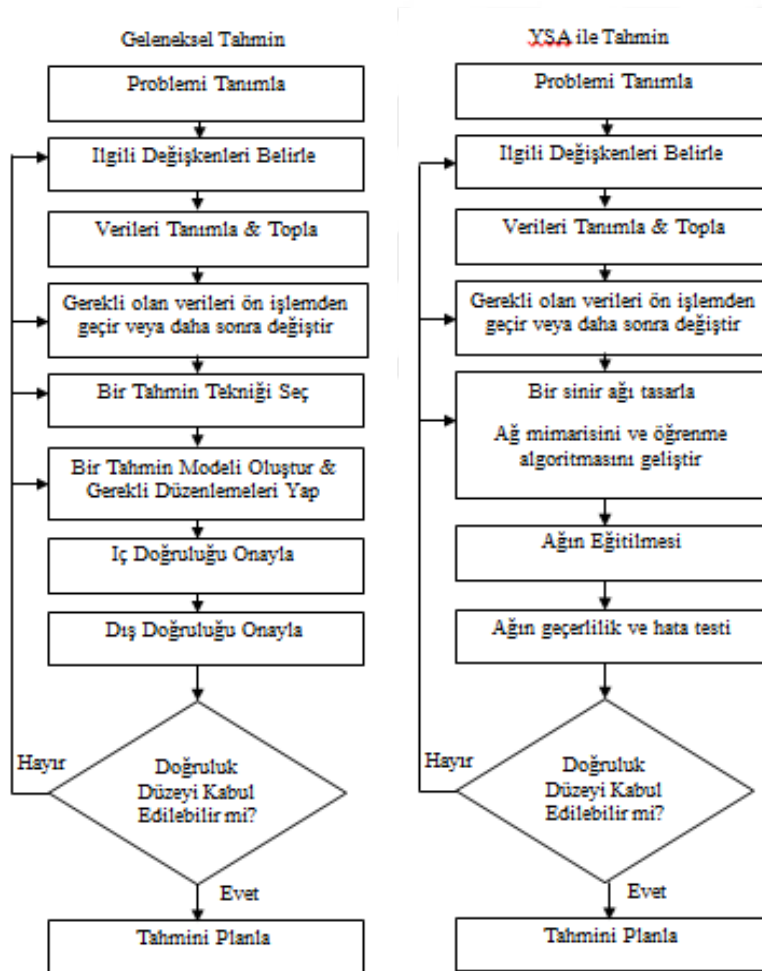
Tablo 3 Yapay sinir ağları ve geleneksel talep tahmin metotlarının karşılaştırılması

	Geleneksel	Yapay Sinir
Öğrenme süresi	-	Uzun
Cevap verme süresi	Uzun	Kısa
Öncelikli bilgi	Gerekli	Sadece örnekler
Bilgi temsili	Zor	Kolay
Rastgele seçilmiş	Zor	Kolay
Performans	Uygun	İyi
Bilgi işleme	Açık	Kapalı
Kaynak	Uzman kişi	Örnekler

Tablo 2, yapay sinir ağları, geleneksel yöntemler ile talep tahmin yöntemleri karşılaştırılmaktadır. Buna göre, geleneksel yöntemlerle tahmin sürecinde, uzman görüşüne ihtiyaç duyulurken, sinir ağları geçmişten gelen örneklerden yararlanarak dıştan müdahale etmeden işlem yapabilir. Ayrıca, sistemin tepki süresi geleneksel yöntemlerde çok uzundur, bu süre sinir ağ yönteminde çok kısadır.

Bugün, yapay zekanın yapay sinir ağları ile değiştirildiği düşünülmektedir. Ancak, uygulamalardaki, yapay sinir ağlarındaki ve uzman sistemlerindeki, kendi uzmanlık alanlarındaki uzmanlık alanlarının her birinin aynı sisteme katılma eğilimi gösterip daha iyi sonuçlar alacağı yönündedir. Bu yeni sistemlere hibrit sistemler denir. Yapay zeka teknikleri aynı sistemde birlikte hareket eder, kendi başlarına olmaktan daha güçlü bir sistem. Tablo X 'de, geleneksel tahmin yöntemlerinin, yapay sinir ağı yöntemi ile tahmin işleme süreci açısından karşılaştırılması, akış diyagramı olarak gösterilmektedir.

Tablo 4 Yapay Sinir Ağları ve Geleneksel Tahmin Süreçleri Karşılaştırması



İki yöntem arasındaki temel fark, sinir ağlarının veri işleme yöntemidir. Geleneksel istatistiksel yöntemde, veri işleme, grup (yığın) ve sırayla, ancak bir kerede;

Yapay sinir ağı yönteminde toplanan veriler tekrar tekrar ağa sunulur. Bu süreç ağın öğrenilmesi tamamlanıncaya kadar devam eder. Bir başka fark, yapay sinir ağlarında veri işlemenin paralel olarak yapılması ve ağa yapay nöronlar aracılığıyla etkileşimli olarak dağıtılmasıdır [8].

Tablo 5, uzman sistemler ve yapay sinir ağları arasındaki benzerlikleri göstermektedir. Uzman sistemlerle karşılaştırıldığında yapay sinir ağı yöntemleri tamamlayıcıdır.

Tablo 5 Yapay sinir ağlarına karşılık gelen uzman sistemler ve elemanlar

Uzman Sistemler	Yapay Sinir Ağları
Şartlar ve sonuçlar	İşlem elemanları (düğümler)
Kurallar	Bağlantılar
Belirsizlik değerleri	Ağırlık değerleri
Gerçekleri toplama	Toplama fonksiyonu
Kuralları çalıştırma	Çıkış fonksiyonu

Tablo 4.2'de görüldüğü gibi, bir uzman sistem (ABD) ile yapay sinir ağları arasındaki ana farklılıklardan biri öğrenme tarzı ile ilgilidir. Uzman sistemlerde, öğrenme yapılamaz veya zordur. Yapay sinir ağlarında, öğrenme süreci oldukça kolaydır çünkü model öğrenme olayına dayanır. Bu yöntemler genellikle tamamlayıcı özelliklere sahiptir. Bu nedenle, son yıllarda, her iki yöntemin birleştirildiği ve birbirlerinin zayıf taraflarının elimine edildiği kombine sistemlerin tasarımı giderek yaygınlaşmıştır [1].

Tablo 5, uzman sistemler ve yapay sinir ağları arasındaki farkları göstermektedir.

Tablo 6 Uzman sistemler ve yapay sinir ağları arasındaki farklar

Parametreler	Uzman Sistemler	YSA
Kullanıcı arabirimi	Mevcuttur	Mevcut değildir
Açıklama yeteneği	Mevcuttur	Mevcut değildir
Uzman kişi	İhtiyacı var	İhtiyacı yok
Örnekler	İhtiyacı yok	İhtiyacı var
Problemin boyutu çoğaldığında bakım	Zorlaşır	Değişmemekte
Oluşturulması	Kurallar, hiyerarşik yapılar	Eğitilmekle
Bilgi işleme	Seri ve karmaşık	Paralel
Bilgi temsili	Kesin ve açık/Sözlü ifade	Saklı/Sözlü ve sayısal ifade
Tam değerlerin belli olması	Şarttır	Şart değildir

Tablo 4.3'te gösterildiği gibi, uzman sistemler ve yapay sinir ağı yöntemleri arasındaki ana farklar; Uzman bilgisi ve müdahale ihtiyacı, örnekleme ihtiyacı, doğru bilgi ihtiyacı ortaya çıkmaktadır.

Yapay sinir ağları bilinen hesaplama yöntemlerinden farklı bir hesaplama yöntemi sunar. Çevrelerine uyum sağlama, uyum sağlama, eksik bilgi ile çalışabilme, belirsizlik altında karar verme, hataya toleranslı karar verme, bu hesaplama yönteminin başarılı bir şekilde uygulanmasında yaşamın hemen hemen tüm alanlarını görmek mümkündür. Ağa yaratılan yapının belirlenmesinde, ağ parametrelerinin seçiminde, belirli bir standardın bulunmaması, sorun yalnızca sayısal verilerle, ağın davranışını açıklayamazken iyi bilinen eğitim ile bitebilir Bu ağlarda her gün artar. Biyolojik sınırlardan ilham alan yapay sinir ağı tasarımı, girdi parametresindeki küçük değişikliklerin tolere edebileceği çevresel değişimin sonucu değiştirebilecek doğrusal ve paralel hesaplama fonksiyonları, önceki verilerde bulunan benzer işlevleri keşfetti. Farklı verilerle karşı karşıya kaldığında, yeni veri değeri konusunda deneyim olmasa bile, Tepki verme gibi üstün özelliklere sahiptir [8].

3.7.5 Yapay Sinir Ağlarının Avantajları

Yapay sinir ağları kullanılarak yapılan analizlerde, elde edilebilecek avantajlardan bazıları şöyle sıralanmaktadır:

- Yapay sinir ağları diğer sistemlerden daha fazla sayıda özelliğe sahiptir. bunlar: Doğrusal olmama, örneklerden öğrenme yeteneği, genelleme yeteneği, uyarlanabilirlik, dağıtılmış birleşik bellek yapısı, paralel işlem kapasitesi, hata ayıklama özelliği, kolay elde edilebilir donanım, hızlı hesaplama, analiz kolaylığı ve tasarım ve program kullanılabilirliği Hazır paketlerin sayısı olarak listelenebilir. [95] , [4].
- Karmaşık sinir ağları matematiksel olarak modellenmesi zor ya da imkansız olan karmaşık sorunları kolayca çözebilir. Yapay sinir ağlarının, geleneksel bilgisayar yazılımı teknolojisi ile çözülemeyen birçok problemi çözme yeteneği, anormal derecede eksik ve güvensiz bilgi ile çalışma yeteneği, paralel olarak dağılma yeteneği gibi sayısız avantajı saymak mümkündür. Öğrenmek ve genelleştirmek

için yapı ve öğrenilen bilginin sinaptik ağırlıkları kullanarak dağınmık hafızasında saklanabilmesi.

- Yapay sinir ağırları, girilen bilgilere göre kendi ilişkilerini oluşturur. Başka bir deyişle, ateist modeller oldukları için denklem içermezler. Ancak, modelde olanlar tam olarak analiz edilemez. Yapay sinir ağırları, bazıları tarafından karmaşık özellikleri nedeniyle akıllı bir kara kutu olarak adlandırılır.
- Model gerektiğinde ancak sınırsız sayıda değişken üzerinde çalıştırılabildiğinden, mükemmel tahminde kesinliğe sahip genel çözümler yaratılabilir. İnsan beyindeki sinir hücrelerinin ölümü nedeniyle bu hücrelerde depolanan bilgilerin tükenmesi tehlikesi olsa da, yapay sinir ağlarındaki matematiksel nöronların hafızasının ölmesi ve hafızasındaki bilgilerin asla kaybolmaması muhtemeldir.
- Yapay sinir ağı yöntemi, girdi veri setindeki artışa oranla daha tutarlı sonuçlar üretebilir. Yapay sinir ağırları birçok çalışmada diğer yöntemler kullanılarak karşılaştırmalı olarak çalışılmış ve özellikle sabit olmayan ve ayrık veri serileri için son derece tutarlı ve güvenilir sonuçlar sağladığı bulunmuştur [44].
- Yapay sinir ağı uygulamaları hem pratik hem de uygun maliyetlidir.
- Zaman verimlidirler.
- Yapay sinir ağırları, yeni bilgiler görüntülediğinde ve çevre değiştiğinde yeniden inşa edilebilir.
- Yapay sinir ağı modeli esnek bir yapıya sahiptir çünkü bunların her biri büyük bir sorunun farklı bölümleriyle ilgilenen çok sayıda işlemciden oluşur ve bağlantı ağırlıkları ayarlanabilir. Bu esnek yapı, ağı bir kısmı zarar görse bile modelin çalışmasını sağlar. Bu durum düşük performansla neden olur, ancak model tamamen kaybolmaz.

3.7.6 Yapay Sinir Ağlarının Dezavantajları

Yapay sinir ağları yukarıda belirtilen avantajların yanı sıra bazı dezavantajlara sahiptir. Bunlardan bazıları şöyle özetlenebilir [20]:

- Yapay sinir ağlarının donanıma bağlı çalışmaları önemli bir sorun olarak görülebilir. Ağların temel varlığının sebeplerinden biri, paralel işlemciler üzerinde

çalışabilecek olmalarıdır. Ağların, özellikle gerçek zamanlı bilgileri işleme yeteneği, paralel olarak çalışabilen işlemcilerin varlığına bağlıdır. Günümüzde bilgisayarların çoğu seri olarak çalıştığından, aynı anda yalnızca bir bilgi işleyebilirler. Seri makinelerde paralel işlem zaman alıcıdır. Bazı sorunları çözmek için gereken tüm paralel işlemcileri çalıştırmak mümkün olmayabilir.

- Yapay sinir ağları her türlü sorunu çözmek için kullanılamaz. Bazı sorunların çözümü asla bulunamayabilir ve yaratılan çözüm setinin gerçek değerle hiçbir ilgisi olmayabilir.
- Uygun ağ yapısının belirlenmesi genellikle deneme yanılma yöntemiyle yapılır. Bu önemli bir sorundur. Çünkü sorun için uygun bir ağ oluşturulmazsa, çözümle ilgili bir sorunun çözülememesi veya performansın düşük olması olasıdır.
- Yapay sinir ağları kabul edilebilir çözümler üretir, ancak en iyi çözümü garanti etmez.
- Bazı şebekelerde, şebekenin parametre değerlerinin belirlenmesinde kural yoktur ve sorun öznedir. Bu, iyi çözümler bulmayı zorlaştıran bir faktör olarak görülebilir. Bu parametrelerin belirlenmesi aynı zamanda kullanıcının deneyimine de bağlıdır. Her problem için ayrı faktörlerin dikkate alınması gerekebilir. Bu parametre değerleri için belirli standartlar oluşturmak çok zor olduğundan, her sorun için ayrı değerlendirmeler gerekir. Bu modelin büyük bir dezavantajı olarak görülebilir.
- Ağın öğreneceği sorunu göstermek çok önemli bir sorundur.
- Yapay sinir ağları yalnızca sayısal bilgilerle çalışır. Veri sunulmadan önce modelin sayısal formata dönüştürülmesi gerekir. Bu, kullanıcının yeteneğine bağlıdır. Bu bakımdan, kullanıcı deneyimi yeterli olmayabilir. Bu durum, birçok olayın yapay sinir ağları tarafından çözülememesinin en önemli nedenlerinden biri olarak kabul edilebilir.
- Ağın eğitiminin ne zaman biteceğine karar vermek için gelişmiş bir yöntem yoktur. Belli bir değer altındaki örneklerdeki ağ hatasını azaltmak, eğitimi tamamlamak için yeterli kabul edilir.
- Diğer bir dezavantaj, ağın davranışının açıklanamamasıdır. Bir soruna bir çözüm üretildiğinde, nasıl ve neden üretildiği hakkında bilgi bulmak mümkün değildir. Bu ağ tarafından üretilen çözümün güvenini azaltır.
- Sorunlara optimum sonuç vermez.

- Yapay sinir ağıları uzun öğrenme süresidir. Yapay bir sinir ağını eğitmek için çok fazla denemeye ihtiyaç vardır. Eğitim zamanının kısaltılması kritiktir, çünkü yapay sinir ağıları tarafından yapılan tahmin deneme yanılma sürecidir; Bu nedenle, sınırlı bir süre içinde ne kadar çok araştırmacı olursa, o kadar sonuç o kadar emin olacaktır.

3.7.7 Yapay Sinir Ağlarının Uygulama Alanları

İlgili literatürde tarandığında, yapay sinir ağıları ile farklı alanlarda binlerce uygulamanın yapıldığı ve başarılı sonuçlar alındığı söylenebilir. İlk yapay sinir ağı çalışması yaklaşık elli yıl önce başlasa da, yöntemin etkili kullanımı ve geliştirilmesi son 20 yılda olmuştur. Ancak, diğer iyileştirmeler (optimizasyon) ve matematiksel yöntemlerin geliştirilmesi uzun yıllar sürdü. Yapay sinir ağı yöntemi; Yüksek öğrenim, araştırma, endüstri ve teknolojik gelişmeler için Bulanık Mantık (BM) ve Genetik Algoritma (GA) yöntemleri çok başarılı bir temeldir. Her yöntemin farklı alanlarda üstün uygulamaları vardır.

Geçmişte laboratuvarlarda çalışmalar yapılmış ve veriler simülasyonla elde edilmiş, yapay sinir ağıları günlük yaşamda ve gerçek verilerle gerçekleştirilmiştir. Yapay sinir ağı uygulamaları, evimizdeki enstrümanlardan cep telefonlarına kadar birçok alanda bulunabilir. Yapay sinir ağlarının uygulamaları; endüstriyel uygulamalar, finansal uygulamalar, askeri ve savunma uygulamaları, sağlık uygulamaları ve diğer uygulamalar [20].

Yapay sinir ağıları, çözülmesi zor ve çok karmaşık olmayan ya da ekonomik olmayan pek çok farklı alanda problemleri çözmek için kullanılmıştır ve bazıları aşağıda verilen başarılı sonuçlardır [5].

- Analiz ve Hata Tespiti: Cihazın veya elemanın normal çalışma modunu deneyimleyen bir sinir ağı kullanan bir sistem, meydana gelebilecek olası sistem arızalarını tahmin etmek mümkündür. Yapay sinir ağıları; arıza analizi için kullanılan elektrikli makineler, uçaklar, entegre devreler vb.

- Tıbbi alan: Yapay sinir ağıları, tıbbi sinyallerin analizi, kanser hücrelerinin tanımlanması, protez tasarımı, transplantasyon zamanlamasının optimizasyonu ve hastane masrafları gibi alanlarda optimizasyon.
- Savunma Sanayii: Silah otomasyonu ve izleme, nesne / görüntü ayırma ve algılama, yeni sensör tasarımı ve gürültü kontrolü gibi alanlarda kullanılır.
- İletişim: Görüntü ve veri sıkıştırma, otomatik bilgi aktarımı, dilin gerçek zamanlı çevirisi bu gibi konularda kullanılır.
- Üretim: üretim sistemlerinin optimizasyonu, ürün analizi ve tasarımı, ürünlerin kalite analizi ve kontrolü, planlama ve yönetim analizi.
- Otomasyon ve Kontrol: Yapay Sinir Ağları, Oto-Pilot Sistem Uçak yapımında otomasyon, otomatik / göstergede taşıma araçlarının bulunması, robot sistemi kontrolü, doğrusal olmayan sistemler Modelleme ve kontrol, elektrik tahrik sisteminin kontrolü gibi alanlarda yaygın olarak kullanılmaktadır.
- İstatistikler: Klasik istatistiksel yöntemler yerine alternatif yapay sinir ağı modellerini kullanan birçok çalışma vardır. Özellikle, regresyon ve küme analizi ile ilgili birçok uygulama vardır.
- Finans: Borsa endeksi tahmini, enflasyon tahmini ve ülkelerin finansal olarak gruplandırması gibi birçok finansal uygulama vardır.

Yapay sinir ağıları, gerçek hayat problemlerinde geniş bir uygulama alanı kazanmıştır. Günümüzde birçok endüstride başarıyla kullanılmaktadır. Uygulama alanları için sınır olmamasına rağmen, sınıflandırma, tahmin ve modellemede daha çok kullanılmaktadırlar. Model verinin eğilimlerini veya yapılarını en iyi tanımlayan bir yöntem olduğundan, tahmin süreci için çok uygundur.

Yapay sinir ağlarının gerçek hayatta yaygın olarak uygulandığı alanlar; Kalite Kontrol, Mali Öngörü [2], Ekonomik Tahmini, Kredi Derecelendirmesi, Laboratuvar Araştırması, İflas Tahmini, Petrol ve Gaz Arama [3], Sistem Modellemesi, Parmak İzi Tanıma, Meteorolojik Yorumlama, Otomatik Araç Muayeneleri, Sağlık İhtiyaçları [25], Kalp fonksiyonları işaretlerin izlenmesi ve değerlendirilmesi gibi [7] verilebilir.

Yapay sinir ağlarının potansiyel uygulama alanları, bazı teknik problemler nedeniyle klasik zekanın çok yavaş veya yetersiz olduğu durumlar olarak tanımlanabilir.

Uygulamalar incelendiğinde, yapay sinir ağlarının genellikle aşağıdaki işlevleri yerine getirmek için kullanıldığı görülmektedir. [20]:

Tahmin: Çıktı değerini, ağa sunulan giriş bilgilerini kullanarak tahmin etmek. Hava tahmini, borsada hisse senedi değeri, gelecekteki satışların tahmini, üretim ihtiyaçlarının belirlenmesi, piyasa performansının belirlenmesi, enerji ihtiyacının belirlenmesi, at yarışlarının tahmini, kanser risk oranlarının belirlenmesi, örneklerin verilmesi gibi örnekler vermek mümkündür. döviz kurları.

Sınıflandırma: Yapay sinir ağları, kendilerine sunulan bilgileri sınıflandırabilir. Buna bir makinedeki hatalar, müşteri / pazar profilleri, imza testleri, malların değerinin belirlenmesi, hücre tiplerinin sınıflandırılması ve borçlanma / risk değerlendirmeleri verilebilir.

Veri ilişkisi: Bu amaç için eğitilmiş ağlar, ağa sunulan verilerin hatalı ve eksik olup olmadığını belirler. Ayrıca eksik bilgileri tamamlarlar ve yanlış olan ek verileri belirlerler. Örneğin, taranan belgedeki karakterleri algılamının yanı sıra, tarayıcının düzgün çalışmadığını tespit edebilirler.

Veri filtreleme: Filtreleme için eğitilmiş ağlar, uygun verileri çeşitli verilerden belirleme görevini yerine getirir. Telefon konuşmalarındaki gürültüyü gerçek konuşmalardan ayırmak ve resimdeki istenmeyen parazitleri temizlemek gibi örnek uygulamalar vardır.

Tanıma ve eşleştirme: Farklı şekil ve kalıpların tanınması, eksik, karmaşık, belirsiz bilgilerin işlenmesi ve eşleştirilmesi ile işlenmesi. Buna bir örnek daha önce verilmiş olan kalite kontrol şemalarındaki şekilleri tanıyabilen sinir ağıdır.

Teşhis: Bu amaç için geliştirilen ağlar, problemleri belirleme ve problemleri belirleme işlemini gerçekleştirir. Bunun bir örneği, makinelerin tanımlanması, arazi koşulları, hastalıklar ve hataların tespitidir.

Yorum: Bir olayda toplanan örneklerden elde edilen bilgileri kullanarak yeni olayların yorumlanması ve eğitimden alınan bilgiler bu kapsamda değerlendirilir. Buna bir örnek, toplanan verilerin istatistiksel dağılımlarının oluşturulmasıdır.

3.8 Yapay Sinir Ağlarının Yapısı ve Temel Elemanları

3.8.1 Yapay sinir ağları temel yapısı

Yapay sinir ağları, hiyerarşik bir yapı içinde birbirine bağlanmış çok sayıda basit işlemci elemanının girdi verilerinden çıkabileceği bir kara kutu olarak tanımlanabilir. Bu kara kutunun işlevi sadece matematiksel bir işlevi temsil etmektir. Yapay sinir ağlarının bu fonksiyonunun matematiksel bir karşılığı yoktur. Başka bir deyişle, modelin matematiksel denklemlere değil, örneklere ihtiyacı var. Modelin öğrenmek için geçmişten sadece örneklere ihtiyacı vardır.

Şekil 3, geçmiş veri girişlerinden sonuç üretebilen kara kutunun simülasyonunu göstermektedir.[20]




Şekil 8 Yapay sinir ağlarının kara kutu benzetimi

Kara Kutuya benzer sinir ağları, tüm hücrelerden bilgi toplama ve bu bilgiyi diğer elemanlara işleme yeteneğine sahiptir. Çeşitli algoritmalar ve yaklaşımlar söz konusudur.

Yapay sinir ağları, gerçek zamanlı olayların deneyimlerinin gerçekleşmesinin gerçekleşmesi gibi, öğrenme sisteminin gerçekleşmesi gibi, bilgi toplamada da bir problem yoktur. Burada kullanılan örnekler, bilgisayarla istenen ilişkileri doğru bir şekilde temsil etmelidir. Sorunun ağa sunulma şekli, ağın topolojik yapısı, ağın kullandığı öğrenme stratejisi ve öğrenme kuralları ağın performansını etkileyecektir. Yapay sinir ağını oluşturan işlemci elemanları birbirleriyle sürekli iletişim halindedirler [22].

Şekil 10 'da yapay sinir ağlarının işleyişi bir blok sema üzerinde gösterilmiştir. [90]



Şekil 9 Yapay sinir ağları yapısı blok gösterimi

Şekil 5 'te gösterildiği gibi, sinir ağı giriş katmanı ara katmandan ve çıkış katmanından oluşur. [20]


Bu seviyeler aşağıdaki gibi betimlendirilebilir:

Giriş Katmanı: Giriş katmanı, en az bir giriş elemanına sahip olan bölümdür. Bu katmandaki veriler, herhangi bir işlem yapmadan girdiyle aynı değeri üretir.

Orta seviye: girişlerin belirli işlemlere tabi olduğu bölümdür. Proses seviyesinin yapısı ve fonksiyonu, seçilen ağ yapısına bağlı olarak da değişebilir. Ara katman, tek bir katmandan veya birden fazla katmandan oluşabilir [98].

Çıkış katmanı: çıkış katmanı en az bir çıkış içerir ve çalışması için çıkış ağına bağlanır. Operasyonlar bu düzeyde gerçekleştirilir ve burada üretilen çıktılar dış dünyaya gönderilir.

Yapay sinir ağlarının süreci Şekil 4.4'te gösterilmiştir. Gösterildiği gibi, geçmişten (nöronlar) ve fiksasyondan (aksonlar) çıktıya veri girdikten sonra işlemci elemanları işlemeye devam eder.



Şekil 10 Yapay sinir ağları işlem süreci

Temel bir sinir ağı hücresi, biyolojik sinir hücresinden çok daha basit bir yapıya sahiptir. Yapay sinir ağı hücreleri temel olarak dış ortamdan veya diğer nöronlardan, yani girdiler, ağırlıklar, toplanma fonksiyonu, aktivasyon işlevi ve çıktılardan veriler içerir. Dış ortamdan gelen veriler nöronla ağırlıklar üzerinden bağlanır ve bu ağırlıklar ilgili girdinin etkisini belirler. Toplama işlevi net girişi hesaplar. Net giriş, girişleri bu girişlerle ilişkili ağırlıklar ile çarpmanın sonucudur. Aktivasyon fonksiyonu işlem sırasındaki net çıkışı hesaplar ve bu işlem nöronu da verir. Genelde, aktivasyon fonksiyonu doğrusal olmayan bir fonksiyondur [5].

3.8.2 Yapay sinir ağları temel elemanları

Biyolojik sinir hücreleri:

Yapay sinir ağlarını daha iyi anlamak için, örnek sinir ağları olan biyolojik sinir ağlarının yapısı ve çalışma prensipleri iyi bilinmelidir. İnsan beyninin, insan beyninin bilgisi tarafından eğitilmiş olup olmadığı henüz belli değildir.

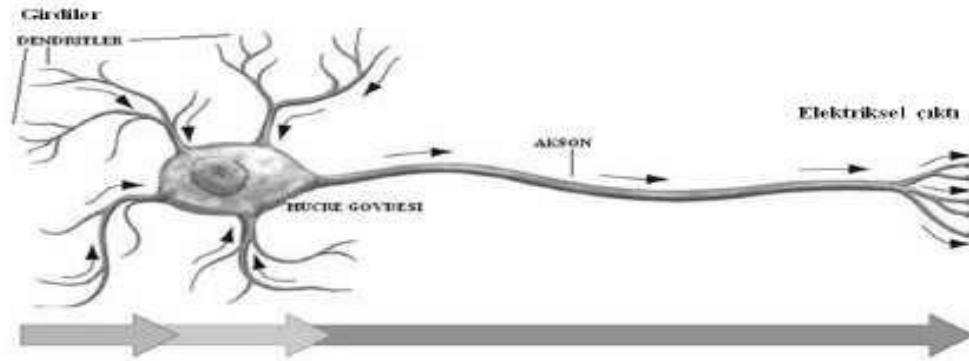
Bu teorilerin çoğuna göre; İnsan beyni, vücudun aktivitesini, biriyle karmaşık ilişki içinde olan milyarlarca sinir hücresi (nöron) ile kontrol eden bir mekanizmadır. Bir insan beyninde, her bir hücre ortamında 10 milyardan fazla sinir hücresi vardır.

10.000 hücreyle bağlantılı olarak çalışır. Bu sinir hücrelerinde, nöron adı verilen sinyaller, saniyede 1000'e ulaşabilen çok karmaşık bir elektro-kimyasal olay zincirinde meydana gelen titreşimler şeklinde iletilir [5].

Bu mekanizma içindeki tipik bir sinir hücresi, komşu hücrelerden gelen sinyalleri dendritler adı verilen ince kılcak kanallar yoluyla toplar ve bunları binlerce sinir hücresi dalına bölünmüş ince ve uzun ayak aksonları yoluyla beyne iletir. Her akson dalının sonunda sinaps adı verilen bir düğüm vardır. Bu düğümler aksonlardan beyne sinyalleri iletir. Beyne iletilen bu sinyaller sayesinde öğrenme olayı gerçekleşir [26].

Biyolojik sinir sistemi bilgi alan, yorumlayan ve uygun kararlar veren bir kontrol merkezidir. Bu kontrol ünitesi reseptör ve yanıt sinirlerinden oluşur [27]. İnsan beyninin temel taşlarından biri olan sinir sistemi, insanların tüm davranışlarını ve çevrelerini anlamalarını sağlar.

Şekil 6, sinaps, akson, soma ve dendritlerden oluşan biyolojik bir sinir hücresini göstermektedir.



Şekil 11 Biyolojik sinir hücresi

Bu mekanizma içindeki tipik bir sinir hücresi, komşu hücrelerden gelen sinyalleri, dendritler adı verilen ince kılcak yollardan toplar ve bunları beyne sinir hücresinin dallarına bölünmüş ince ve uzun ayak aksonları yoluyla beyne iletir. Her akson dalının sonunda, sinaps adı verilen bir düğüm vardır. Bu düğümler aksonlardan beyne sinyalleri iletir. Beyne iletilen bu sinyaller sayesinde öğrenme olayı gerçekleşir [26].

Biyolojik sinir sistemi, bilgiyi alan, yorumlayan ve uygun kararlar veren bir kontrol merkezidir. Bu kontrol ünitesi reseptör ve yanıt sinirlerinden oluşur [27]. İnsan beyninin temel taşlarından biri olan sinir sistemi, insanların tüm davranışlarını ve çevrelerini anlamalarını sağlar.

Şekil 7, sinaps, akson, soma ve dendritlerden oluşan biyolojik bir sinir hücresini göstermektedir. [24]



Şekil 12 Sinir sisteminin blok gösterimi

Şekil 13, bilginin getirilmesiyle birlikte insan sinir sisteminin insan sinir sistemini gösterirken, bu bilginin dönüşümüne cevap olarak merkezi sinir sistemi gösterilmesinin bir sonucu olarak gösterilmektedir.

Sinir ağ sistemi, insan beyninin temel parçalarından biridir, ancak mikroskop tarafından görülebilecek kadar küçüktür. Nöronlar şaşırtıcı bir şekilde karmaşık bir biyokimyasal ve elektriksel sinyal işleme tesisi olarak düşünülebilir [34].

Yapay sinir hücreleri: Yapay nöronlar sinir ağlarının en temel birimleridir. Yapay sinir ağları, yapay nöronları, aralarında bir bağlantı kurarak katmanlar halinde katmanlandırılarak oluşturulmaktadır.

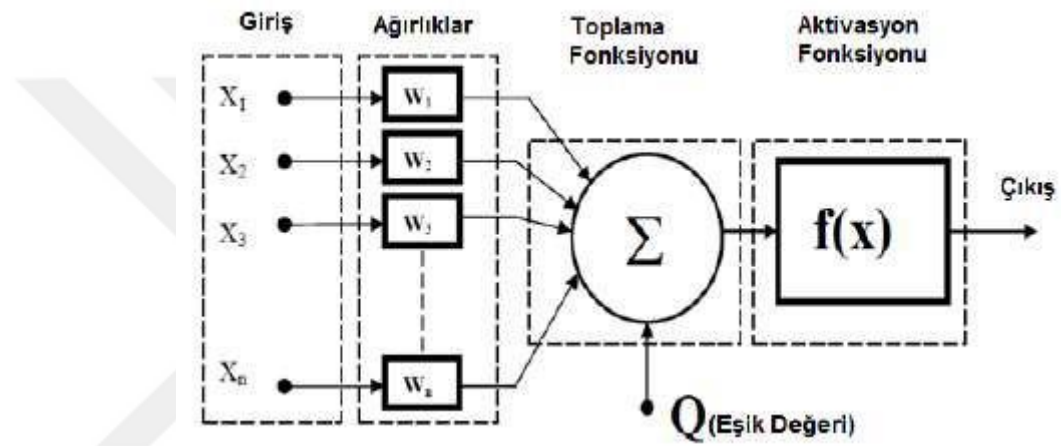
Nöronal hücreler, biyolojik nöronların temel davranışlarını tespit etmenin fiziksel yollarından ilham alan bir algoritma veya matematiksel model olarak tanımlanabilir. Biyolojik sinir hücrelerinin tanımına göre, diğer sinir hücrelerinden geçen yapay bir sinir hücresi ve toplam sinyal birikim süresi belli bir eşiği aştığında, alan sinir hücreleri başka bir sinire mesaj gönderen yerinde sinyalleri alabilir. kendi sinyal hücresi [35].

Metodolojideki yapay sinir ağları, sinir sisteminin biyolojik nöronlarının temel işlem birimidir ve biyolojik sinir sistemindeki gibi herhangi bir matematiksel olarak modellenemez. Giriş veri yapısının dışındaki bir sinir ağı yapıldığında, insan sinir sistemi gibi yapay modeller, bu girdiler matematiksel yapay nöronlarda iş ve çıktı üretebilir. İlk değerler, başlangıçta istenen üretime göre çok fazla kapatılabilir, ancak öğrenme

sürecindeki nöronlar arasındaki sinaptik yarık, bazı yakınsamaları tamamlamak için yapay ağırlıklar oluşturmaya devam eder ve öğrenme kurulur. Buna göre, meydana gelen biyolojik sinir ağı modellemesini taklit eden yapay bir sinir ağıdır.

Şekil 14 yapay sinir hücrelerinin matematiksel fonksiyonlarını katmanlar halinde göstermektedir.

Şekilde gösterildiği gibi, her girişteki değişiklik, çıkış nöronunda belirli bir değişikliğe neden olur ve bu büyüklükteki değişiklik, girişin ciddiyetine bağlı olacaktır.



Şekil 13 Yapay sinir hücrelerinin matematiksel yapısı

Şekil 13, X_i sembolünün giriş verilerini, W_i sembolünün kazanç ağırlıklarını, Q sembolünün ilave fonksiyonunu, Q sembolünün eşik değerini, $f(x)$ sembolünün aktivasyon fonksiyonunu gösterir.

Yapay sinir hücreleri, mühendislik bilimindeki beş bileşenden oluşur. Sürecin her elemanı beş temel unsurdan oluşur ve bunlar:

Girdiler: Yapay sinir hücresine dış dünyadan gelen bilgilerdir. Bilgiler dış dünyadan geldiği gibi başka hücrelerden veya kendisinden de gelebilir. Girişlerin verileri bir sonraki aşamaya iletmekten başka hiçbir işlevi bulunmamaktadır. Başka bir ifadeyle girişler veri üzerinde hiçbir matematiksel işlem yapmadan sadece bir iletici görevi yapmaktadırlar. Girişler, yapay sinir ağlarının dış dünya ile ilişki halinde olan iki

elemanından biridir. Bir nöronun çevreyi algılamasına bağlı olarak sınırsız sayıda girişi olabilir fakat her bir nöronun sadece tek bir çıkışı olmak zorundadır. Girdiler, yapay sinir ağlarının algılayıcıları nitelendirilebilir.

Ağırlıklar: Yapay sinir sistemine girilen veriler, bağlantılar üzerindeki ağırlıklar aracılığıyla hücreye girerek bulunduğu giriş hücresini etkilerler. Ağırlıkların bir başka özelliği de nörona girdi olarak kullanılan değerlerin, matematiksel katsayısı olmalarıdır. Girdiler ile nöronlar arasında iletişimi sağlayan bütün bağlantıların değişik ağırlık değerlerinin olması, ağırlıkların tüm işlem elemanları üzerinde etkili olmasını sağlamaktadır. Ağırlıklar hücreye gelen bilgilerin hücre üzerindeki etki ve önemini gösterir. Yapay sinir ağları, öğrenme işlevini ağırlıkların değiştirilmesi sayesinde başarabilmektedir. Ağırlıklar, biyolojik sinir hücresindeki aksonlar olarak düşünülebilirler. Ağırlıkların başlangıç değerleri genellikle (-1 ile +1) aralığında rastgele seçilmektedir[1].

Toplama işlevi: biyolojik nörondaki dendritlerin işlevini toplama işlevi aslında en çok kullanılan birleştirme işlevi türüdür. Bir hücrenin net girişlerini hesaplayan ve genellikle karşılık gelen ağırlık ile çarpılan girdilerin toplamı olarak ifade edilen bir fonksiyondur. Bu fonksiyon hücreye net girişi hesaplar. Toplama işlevi farklı işlevlere sahip olsa da en çok kullanılan işlev ağırlıklı ekleme işlevidir [13]. En çok kullanılan ağırlıklı toplam fonksiyon. Bu işlev aşağıdaki gibi formüle edilmiştir.

$$\text{Net} = \sum G_i \cdot A_i \quad (n=1, \dots, n)$$

Burada G giriş, A ağırlık ve n girişlerin sayısıdır (işlem elemanı). Bir problem için en uygun tespit fonksiyonunu belirleyen bir formül yoktur.

Her işlem elemanı bağımsız olarak farklı bir toplama fonksiyonuna veya aynı toplama fonksiyonuna sahip olabilir. Ekleme işlevine aşağıdaki işlevler atanabilir:

$$\text{Çarpım: NET} = \sum G_i \cdot A_i$$

$$\text{Maksimum: NET} = \text{Max} (G_i \cdot A_i)$$

$$\text{Minimum: NET} = \text{Min} (G_i \cdot A_i)$$

$$\text{Çoğunluk : NET} = \sum \text{sgn} (G_i \cdot A_i)$$

$$\text{Kümülatif Toplam : NET} = \text{NET}_{(\text{eski})} + \sum (G_i \cdot A_i)$$

Aktivasyon Fonksiyonu: Bu fonksiyon hücreye net girişi işler ve hücrenin bu girdi için ürettiği çıkışı belirler. Ekleme işlevinde olduğu gibi, aktivasyon işlevinde çıktıyı hesaplamak için farklı formüller kullanılır. Bazı modellerde, bu fonksiyonun türevi, gerçekleştirilecek bir fonksiyon olmalıdır. Enable işlevinde, ağıın işlemci öğelerinin aynı işlevi kullanması gerekmez. Öğelerden bazıları aynı işlevdir, diğerleri ise farklı işlevleri kullanabilir. Sorun durumlarının bir sonucu olarak, kompozisyon tasarımcısının en uygun işlevi kendisi için belirleyebilir. Genellikle, tercihen doğrusal olmayan bir fonksiyondur. Sinir ağının bir fonksiyonu olarak çalışan aktivasyon seçilir ve veriler ne öğrendiğimize bağlı olarak değişir. En sık kullanılan tipler doğrusal, sigmoidal ve teğetsel hiperbolik fonksiyonlardır.

Aktivasyon fonksiyonları, çıkış değerlerinin belirli sınırlar içinde kalmasını sağlar. Ekleme işlevinde olduğu gibi, işlemci öğeleri etkinleştirme işlevinde farklı işlevler kullanabilir. Çok katmanlı sensör modelleri sigmoid işlevini kullanır [16], [20].

$$\text{Sigmoid Fonksiyonu: } F(\text{NET}) = 1 / (1 + e^{-\text{NET}})$$

Burada NET, proses elemanının net giriş değerini temsil eder. Aktivasyon fonksiyonuna aşağıdaki fonksiyonlar atanabilir:

Lineer Fonksiyon:	$F(\text{NET}) = \text{NET}$
Step Fonksiyonu:	$F(\text{NET}) = 1 \text{ Net} > \text{eşik değeri}$
	$F(\text{NET}) = 0 \text{ NET} \leq \text{eşik değeri}$
Sinüs Fonksiyonu:	$F(\text{NET}) = \text{Sin}(\text{NET})$
Çoğunluk:	$F(\text{NET}) = 0 \text{ NET} \leq 0$
	$F(\text{NET}) = \text{NET} \text{ } 0 < \text{NET} < 1$
	$F(\text{NET}) = 1 \text{ NET} > 1$
Hiperbolik Tanjant Fonksiyonu:	$F(\text{NET}) = \frac{e^{\text{NET}} + e^{-\text{NET}}}{e^{\text{NET}} - e^{-\text{NET}}}$

Hücre çıkışı: Aktivasyon fonksiyonu tarafından belirlenen çıktı değeri. Üretilen çıktı dış dünyaya veya başka bir hücreye gönderilir. Hücre ayrıca çıktısını girdi olarak da gönderebilir. Aktivasyon fonksiyonundan sonra elde edilen sonuç çıkış değeri olarak adlandırılır. Çıkış fonksiyonu; Aktivasyon fonksiyonundan $Y = f(v_i)$ çıktıyı dış dünyaya ağın son çıkışı olarak ya da nöronun bağlı olduğu diğer nöronlar için girdi olarak göndermekten sorumludur. Yapay sinir ağları, tek bir nörondan oluşur; bu ağ, Y çıkışını dış dünyaya nihai çıkış olarak gönderir.

Biyolojik Sinirler ile Yapay Sinirlerin Karşılaştırılması: Beyin ve sinir sisteminin tam yapısı, iç yapısı ve bugünkü çalışma şekli sağlıklı bir karşılaştırmayı zorlaştırır. Bununla birlikte, bilgisayarlardaki ve bilgisayar ağlarındaki gelişmeler, insan beyninin ve sinir sisteminin en küçük detaya değil bir dereceye kadar ilerlemesine yardımcı olmuştur ve yapay sinir ağları yönteminin geliştirilmesiyle, belirli bir düzeyde düzen tasarlanmıştır. sinir sisteminin taklidi. Beyin ve sinir sistemi hakkında ayrıntılı bilgi verildiğinde, çok daha sağlıklı bir karşılaştırma mümkün olacaktır.

Tablo 7, biyolojik sinir hücresi elemanlarına karşılık gelen yapay sinir hücresi elemanlarını göstermektedir.

Tablo 7 Biyolojik sınırlar ile yapay sınırların karşılaştırılması

İşlem Birimi		
Biyolojik Sinir Ağı	Yapay Sinir Ağı	Görevleri
Dendrit	Alıcı ve Toplayıcı	Çevreden gelen veriyi alır
Akson	Verici	Gövdenin oluşturduğu veriyi iletir
Hücre Gövdesi	Aktivasyon Fonksiyonu	Gelen veriyi toplayarak yorumlar ve veriyi oluşturur
Sinaptik Ağırlıklar	Bağlantı Ağırlıkları	Öğrenilenleri hafızada saklar

Tablo 7 'da yapay sinir ağları, insan sinir sistemindeki mekanizmaları taklit etmekte ve yapay elemanlarla aynı işlevleri yerine getirmektedir.

Yapay sinir ile biyolojik sınırların işleme elementleri arasındaki benzerlikleri karşılaştırdı. Tablo 7 biyolojik sinir hücrelerinin ve yapay sinir hücrelerinin işlevsellik açısından karşılaştırmasını göstermektedir [6].

Tablo 8 Biyolojik sinir hücresi ile yapay sinir hücresinin karşılaştırılması

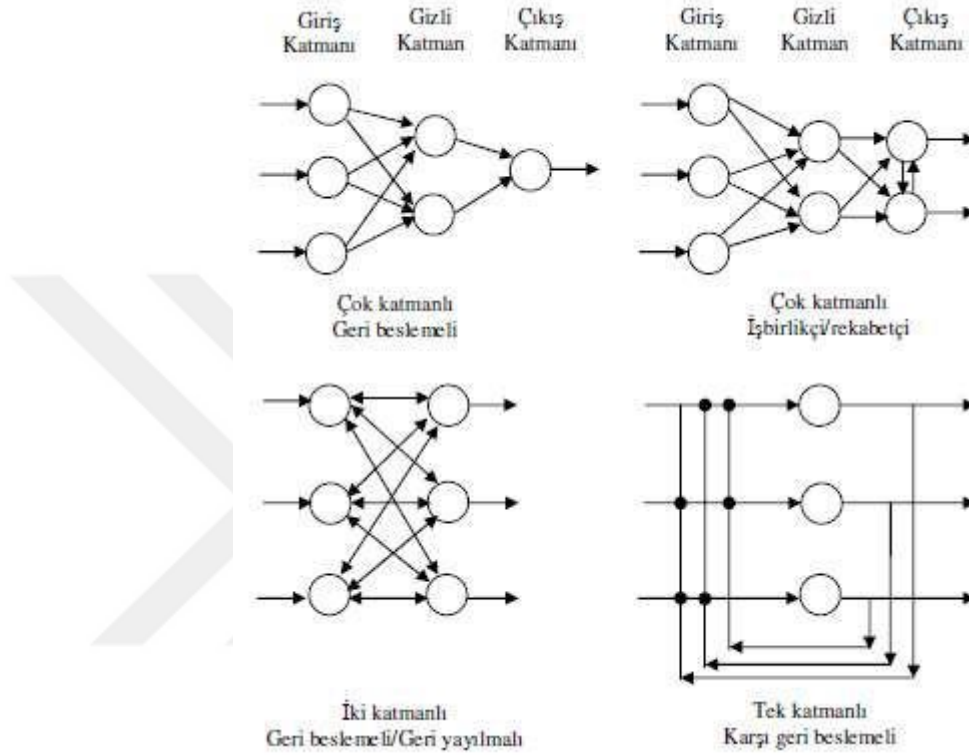
Biyolojik Sinir	Yapay Sinir Ağı
Sinir Sistemi	Sinirsel Hesaplama Sistemi
Sinir	Düğüm (sinir, işlem elemanı)
Sinaps	Sinirler arası bağlantı aralıkları
Dendrit	Toplama işlevi
Hücre Gövdesi	Etkinlik işlevi
Akson	Sinir Çıkışı

Tablo 8, biyolojik sinir sistemi ile yapay sinir ağları arasında benzerlik gösteren benzer noktaları göstermektedir. Görülebileceği gibi, insanlarda sinir sistemindeki her eleman, yapay sinir sistemindeki bir yanıtla tasarlanmıştır.

3.8.3 Yapay Sinir Ağlarının Sınıflandırılması (YSA Mimarileri)

Yapay sinir ağları, sinir hücrelerinin farklı şekillerde bağlanmasından ibarettir. Hücre çıkışları ağırlıklar üzerinden diğer hücrelere veya kendilerine bağlanabilir ve

gecikme ünitesi bağlantılarda kullanılabilir. Hücrelerin ilişkileri, öğrenme kuralları ve aktivasyon fonksiyonlarına göre farklı modeller geliştirilmiştir. Birçok nöronlu yapay sinir ağları, belirli topolojiler (mimariler) ile tanımlanabilir. Bu mimarilerin en yaygın olanı Şekil 14 'te gösterilmektedir.



Şekil 14 Yapay sinir ağları mimarileri


Şekil 15 'te görülebileceği gibi, ağlar katmanlar halinde ve çoklu katmanlar halinde ayrılabilir. Tipik olarak, bir model, istenen çıktıyı almak üzere yapılandırılmış bir girdi katmanına, çıktıların elde edildiği bir çıktı katmanına ve girdi ve çıktı katmanları arasında en az bir gizli katmana sahiptir. En az bir veya daha fazla gizli katman olmalıdır, çünkü gizli katman olmadan bir çıktı doğrudan mümkün değildir [34].

Yapay sinir ağları iki farklı yapıdaki yapılarına, ileri beslemelerine ve geri bildirimlerine göre çalışılabilir.

3.8.3.1 İleri Beslemeli YSA

İleri beslemeli ağlarda, işlemci elemanları genellikle seviyelere ayrılır. Sinyaller, giriş seviyesinden, tek yönlü bağlantıları olan çıkış katmanına iletilir. İşlemci elemanları, bir katmandan diğerine bağlandıklarında aynı seviyede bağlantılara sahip değildir. Besleme ağlarına örnek olarak çok katmanlı sensörler (MLP) ve dijital öğrenme ağları (LVQ) verilebilir [27].

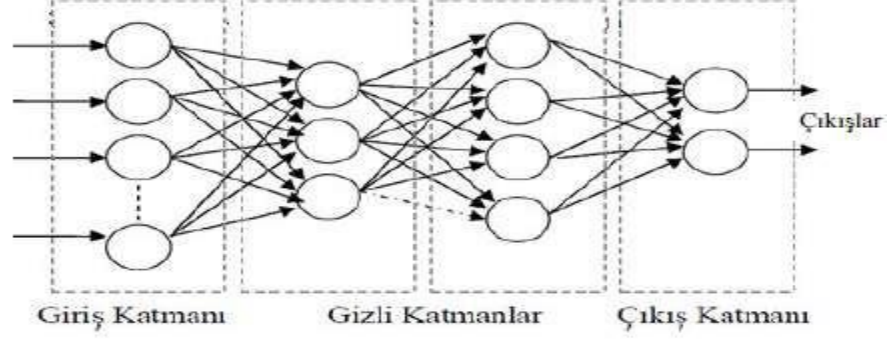
Şekil 16 'de, ileri beslemeli sinir ağı operasyonu bir blok şema olarak ifade edilir.



Şekil 15 İleri Beslemeli YSA

İletilen sinir ağı, giriş seviyesinde herhangi bir giriş seviyesi işlemi olmadan bir sonraki seviyeye gönderilir. Gizli katmandaki işlemci elemanlarının sayısı, giriş problemlerinin sayısına bağlı olarak sistem veya tasarımcı tarafından belirlenebilir. Gizli seviyedeki işlemci sayısı, orta seviye sayısı ve orta seviye sayısı deneme ve yanılma ile de bulunabilir.

Şekil 17, iki girişli bir sinir ağı için, biri çok katmanlı ve bir gizli katman ve iki ara katman içeren çok katmanlı bir besleyici modelini göstermektedir.

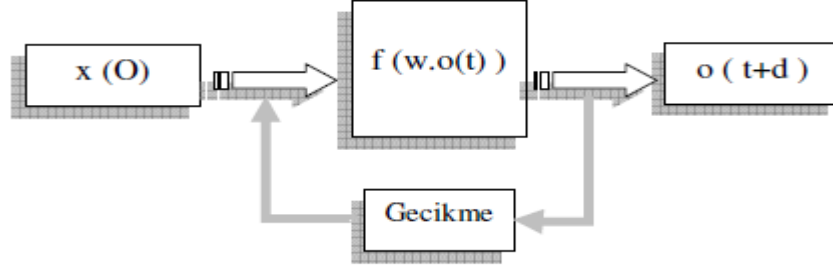


Şekil 16 İleri beslemeli çok katmanlı yapay sinir ağı

3.8.3.2 Geri Beslemeli YSA

Geri besleme sinir ağlarında, en az bir işlemci elemanının çıktısı kendisine veya diğer işlemci elemanlarına girilir ve genellikle geri bildirim bir geciktirme elemanı (ara kat veya çıktındaki aktivasyon değerlerini taşımaktan sorumlu olan ajan) üzerinden yapılır. sonraki yinelemeye girdi olarak katman). Geri besleme katmanlar arasındaki işlemci elemanları arasında olduğu gibi bir katmandaki işlemci elemanları arasında da olabilir. Bu yapıyla, geribildirim sinir ağları doğrusal olmayan dinamik davranış sergilerler. Böylece, geri bildirim nasıl yapıldığına bağlı olarak, geri bildirim yapay sinir ağları, farklı yapı ve davranışlarda elde edilebilir. Geri besleme sinir ağları karmaşık bir işletim mekanizmasına sahipken, dinamik tahminleri nedeniyle ön tahmin uygulamalarında başarılı sonuçlar vermektedir [27].

Şekil 18, geri bildirim sinir ağının ve geri bildirim olayının genel çalışmasını sembolik olarak göstermektedir.



Şekil 17 Geri Beslemeli YSA

Şekil 18 'de gösterildiği gibi, nöral geri besleme ağlarında en az bir hücrenin çıkışı, kendisine veya diğer hücrelere girdi olarak sağlanır. Geri bildirim genellikle bir gecikme ögesinde gerçekleştirilir. Geribildirim katmanlar arasındaki hücreler arasında ve bir seviyedeki hücreler arasında olabilir. Bu yapı ile, sinirsel geribildirim ağları doğrusal olmayan dinamik davranış göstermektedir.

3.8.4 Yapay Sinir Ağlarının Temel Öğrenme Kuralları

Yapay sinir ağlarında öğrenme süreci, istenen çıktıları elde etmek için bağlantı ağırlıklarının belirlenmesinden oluşur. Öğrenme, yapının iyi çalışmasına neden olabilecek mevcut örnekler arasındaki bağlantı ağırlıklarının hesaplanmasıdır. Sinir ağları tarafından öğrenme sırasında edinilen bilgiler sinir hücresi ağırlıkları olarak depolanır. Bu ağırlık değerleri, sinir ağlarının verileri işleme için gerekli olan bilgilerdir.

Öğrenme, örnek öğrenme olarak gerçekleşir. Örneklerden öğrenmenin temel felsefesi, bir olayın geçmiş örneklerini kullanarak, olayın girdileri ve olaylarının çıktıları arasındaki ilişkileri kullanarak gelecekteki yeni çıktıları tanımlamaktır.

Öğrenmenin gerçekleşmesi için, yapay nöronlar arasındaki sinaptik ağırlıkların optimum şekilde ayarlanması gerekir. Yapay sinir ağları, klasik programlama gibi belirli bir algoritma içinde programlanmaz.


Yapay sinir ağları insanlar gibi örnekler ile eğitilmiştir. Yapay sinir ağlarının öğrenilmesi birçok kişinin öğrenmesiyle karşılaştırılabilir. Çocuklar sıcak bir nesneye dokunmamaları gerektiğini öğrenerek, zamanla daha az ılık olan bir nesneye dokunmaya cesaret etmeyi ve bardağı ılık sütle elleriyle tutmayı öğrenir. Başka bir deyişle, çocuklar deneyim sonucu sıcaklık bilgisini öğrenmişlerdir. Benzer şekilde, yapay nöronlar;

Mevcut örnek serilerinde, giriş ve çıkış arasındaki sinaptik ağırlıklar değiştirilerek oluşturulur. Bu yolla sinir ağı, geçmiş deneyimlerine dayanarak problem çözme yeteneklerini geliştirebilir.

3.8.4.1 Gözetimli (Öğretmenli) Öğrenme Yöntemi

Öğrenmenin gerçekleşmesi için, yapay nöronlar arasındaki sinaptik ağırlıkların optimal olarak ayarlanması gerekir. Yapay sinir ağı, klasik programlama gibi belirli bir algoritma içinde programlanmaz.

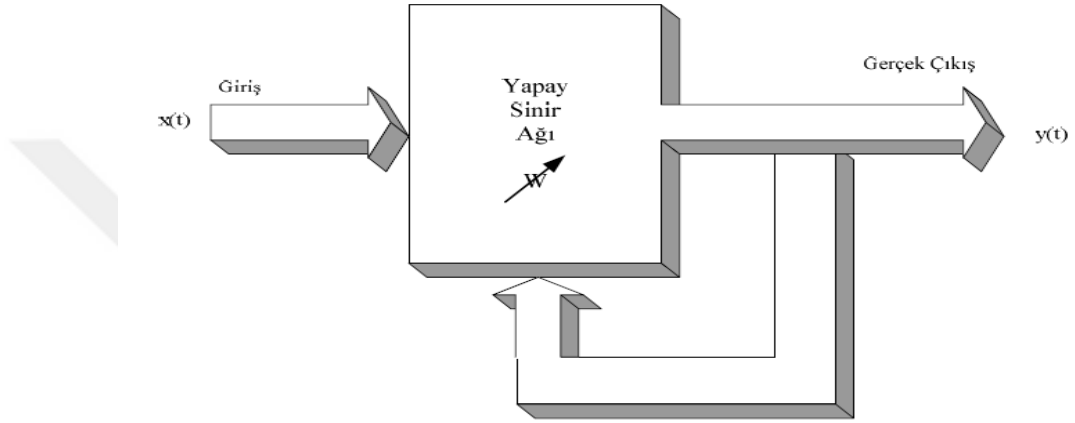
Yapay sinir ağı insanlar gibi örneklerle eğitilmiştir. Yapay sinir ağının öğrenilmesi birçok kişinin öğrenmesiyle karşılaştırılabilir. Çocuklar, sıcak bir nesneye dokunmamaları gerektiğini öğrenerek, zamanla daha az sıcak olan bir nesneye dokunmaya cesaret etmeyi ve bardağı elleriyle sıcak sütle doldurmayı öğrenmeye çalışır. Başka bir deyişle, çocuklar deneyim sonucu sıcaklık bilgisini öğrenmişlerdir. Benzer şekilde, yapay nöronlar; Mevcut örnek setinde, giriş ve çıkış arasındaki sinaptik ağırlıkların değiştirilmesiyle eğitilirler. Bu şekilde sinir ağı, geçmiş deneyimlerine dayanarak problem çözme yeteneklerini geliştirebilir.



Şekil 18 Gözetimli Öğrenme

3.8.4.2 Gözetimsiz (Öğretmensiz) Öğrenme Yöntemi

Bu yöntemde, öğrenilecek sistemin öğretmeni yoktur. Bu, yalnızca giriş değerlerinin görüntülediği anlamına gelir. Örneklerdeki parametreler arasındaki ilişkiler sistemin kendisinden öğrenilmelidir. Kullanıcı, sistem öğrenmeyi bitirdikten sonra çıktıların ne anlama geldiğini belirlemelidir. Bu yöntemler çoğunlukla sınıflandırma için kullanılır.



Şekil 19 Gözetimsiz Öğrenme

DÖRDÜNCÜ BÖLÜM

4.UYGULAMA VE YÖNTEMLER

Bu bölümde çalışmada kullanılacak veri seti ve algoritmalara değinilecektir.

Tablo 9 Çalışma Veri Seti

OD	K	FO	DU	SE	SEGMENT	SATIS	S
		RMAT	RUM	ZON	_TANIM	_ALAN	ANAL
3	672	5	1	0	2	3815	1
4	721	1	1	0	24	464	0
4	559	1	1	0	44	409	0
4	762	1	1	0	21	250	0
4	772	1	1	0	21	437	0
3	328	1	1	0	21	445	0
4	315	1	1	0	31	287	0
4	720	1	1	0	21	550	0
3	281	1	1	0	21	530	0
4	285	1	1	0	11	449	0
4	289	1	1	0	21	383	0
4	381	1	1	0	12	530	0
4	643	1	1	0	12	406	0
4	291	1	1	0	21	330	0
4	317	1	1	0	11	348	0
3	078	1	1	0	12	482	0
4	314	1	1	0	22	550	0
4	690	1	1	0	21	423	0
4	595	1	1	0	44	595	0

4 771	1	1	0	21	452	0
3 301	1	1	0	22	507	0
2 637	1	1	0	12	362	0
4 746	1	1	0	22	559	0
4 831	1	1	0	44	350	0
4 716	1	1	0	21	568	0
4 751	1	1	0	21	640	0
4 741	1	1	0	21	673	0
4 896	1	1	0	22	415	0
3 661	1	1	0	22	598	0
2 504	2	1	0	32	1100	1
4 732	2	1	0	34	786	0
4 785	2	1	0	31	847	0
4 722	2	1	0	34	885	0
3 875	2	1	0	44	1119	0
4 846	2	1	0	44	772	0
4 471	2	1	0	34	752	0
3 074	2	1	0	31	1360	0
4 325	2	1	0	21	972	0
4 386	2	1	0	32	728	0
3 101	2	1	0	32	667	0
4 863	2	1	0	44	1296	0
4 813	2	1	0	31	1323	0
2 601	2	1	0	21	1051	0
3 333	2	1	0	32	755	0
4 596	2	1	0	44	947	0
3 989	2	1	0	32	705	0
4 778	2	1	0	31	782	0

4 856	2	1	0	31	843	0
4 844	2	1	0	42	1366	0
3 019	2	1	0	41	1527	0
3 075	2	1	0	31	1206	0
4 739	2	1	0	31	705	0
4 852	2	1	0	44	1346	0
4 769	2	1	0	32	1217	0
3 336	2	1	0	31	1171	0
4 781	2	1	0	31	832	0
2 483	2	1	0	31	1108	0
4 872	2	1	0	44	1036	0
4 845	2	1	0	44	994	0
2 804	2	1	0	31	1329	0
3 076	2	1	0	32	1038	0
4 602	2	1	0	31	1056	0
3 337	2	1	0	22	1480	0
4 558	2	1	0	44	933	0
4 761	2	1	0	31	887	0
4 536	3	1	0	41	1787	1
4 601	3	1	0	42	1530	1
2 539	3	1	0	42	2101	1
4 824	3	1	0	43	1900	1
3 121	3	1	0	42	1498	1
3 344	3	1	0	32	1977	1
4 849	3	1	0	42	1183	0
3 104	3	1	0	41	1972	0
3 325	3	1	0	31	1720	0
3 240	3	1	0	31	2072	0

4 867	3	1	0	44	1417	0
4 857	3	1	0	44	1380	0
3 103	3	1	0	43	2238	0
4 512	3	1	0	44	1560	0
4 827	3	1	0	42	1795	0

Tablo 10 Çalışma Veri Seti (devamı)

Hesaplamaların ve ileriye dönük tahminlemelerin yapılacağı 36 aylık periyod, 2016-2017-2018 yılları Tablo 10 'da belirtilmiştir.

Tablo 11 Çalışma Yapılacak Dönem Tablosu

1.1.16	1.2.16	1.3.16	1.4.16	1.5.16	1.6.16	1.7.16	1.8.16	1.9.16	1.10.16	1.11.16	1.12.16
1.1.17	1.2.17	1.3.17	1.4.17	1.5.17	1.6.17	1.7.17	1.8.17	1.9.17	1.10.17	1.11.17	1.12.17
1.1.18	1.2.18	1.3.18	1.4.18	1.5.18	1.6.18	1.7.18	1.8.18	1.9.18	1.10.18	1.11.18	1.12.18

Hesaplamalara etki durumunun inceleneceği “resmi tatil” parametresi, resmi çalışma haftası olan Pazartesi haftabaşı, Cuma haftasonu durumu ışığında ilgili veriler toplanmış olup, hesaplamalara Tablo 11 'de olduğu şekli ile dahil edilmiştir.

Tablo 12 2016 - 2017 Yılları Resmi Tatil İş Günü Sayı Tablosu

1.1.16	1.2.16	1.3.16	1.4.16	1.5.16	1.6.16	1.7.16	1.8.16	1.9.16	1.10.16	1.11.16	1.12.16
1	0	0	1	0	0	3,5	1	4,5	1	0	0
1.1.17	1.2.17	1.3.17	1.4.17	1.5.17	1.6.17	1.7.17	1.8.17	1.9.17	1.10.17	1.11.17	1.12.17
1	0	0	0	1	2	0	1,5	1	0	0	0

4.1 İstatistik Yöntemler

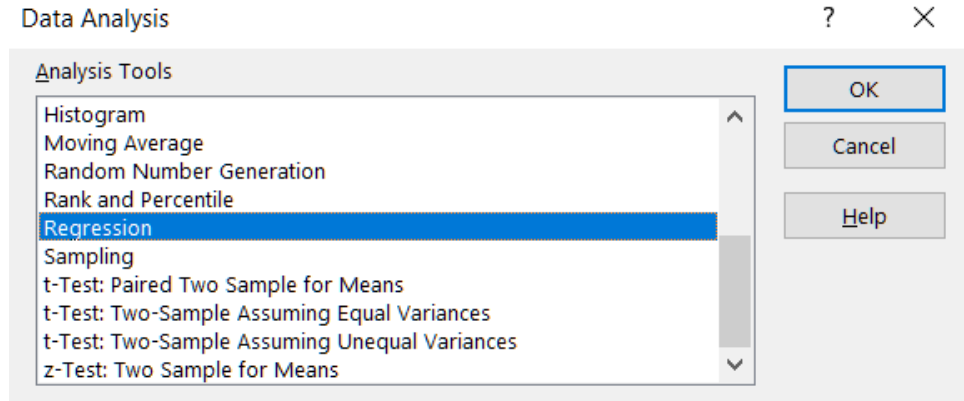
4.1.1 Zaman Serileri Veri Seti

Çalışmada kullanılacak veri seti Tablo 13 'te gösterildiği gibidir.

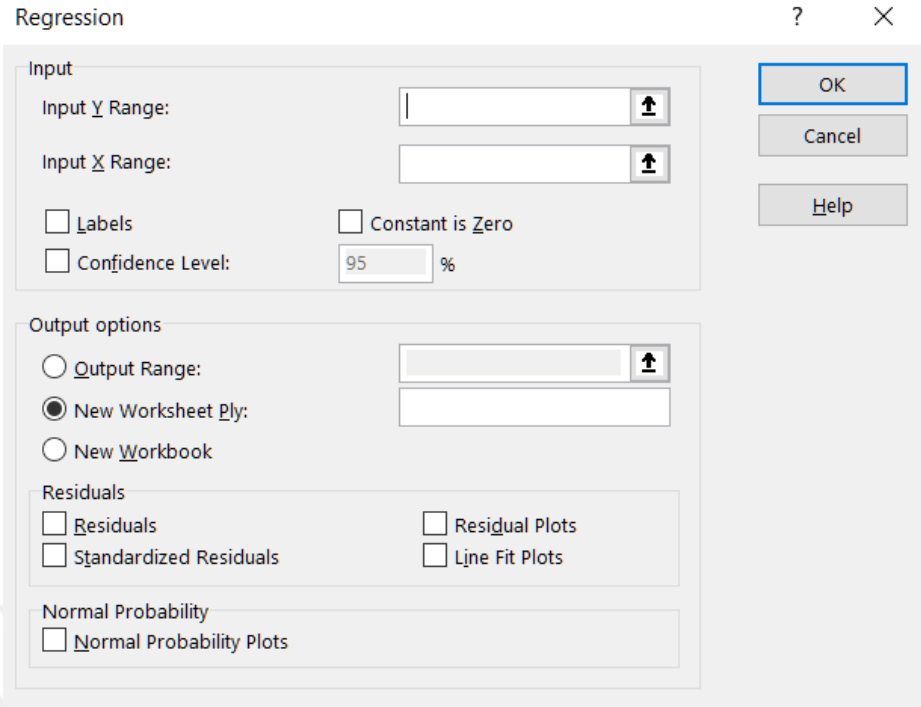
Tablo 13 Zaman Serileri Veri Seti

	INTERCEPT	AY-SIRA	OCAK	ŞUBAT	MART	NİSAN	MAYIS	HAZİRAN	TEMMUZ	AĞUSTOS	EYLÜL	EKİM	KASIM	ARALIK	GERCEK BASKI
OCAK	1	1	1	0	0	0	0	0	0	0	0	0	0	0	4607
ŞUBAT	1	2	0	1	0	0	0	0	0	0	0	0	0	0	4894
MART	1	3	0	0	1	0	0	0	0	0	0	0	0	0	4643
NİSAN	1	4	0	0	0	1	0	0	0	0	0	0	0	0	5865
MAYIS	1	5	0	0	0	0	1	0	0	0	0	0	0	0	4669
HAZİRAN	1	6	0	0	0	0	0	1	0	0	0	0	0	0	3767
TEMMUZ	1	7	0	0	0	0	0	0	1	0	0	0	0	0	4573
AĞUSTOS	1	8	0	0	0	0	0	0	0	1	0	0	0	0	3520
EYLÜL	1	9	0	0	0	0	0	0	0	0	1	0	0	0	5869
EKİM	1	10	0	0	0	0	0	0	0	0	0	1	0	0	4421
KASIM	1	11	0	0	0	0	0	0	0	0	0	0	1	0	4835
ARALIK	1	12	0	0	0	0	0	0	0	0	0	0	0	1	6150
OCAK	1	13	1	0	0	0	0	0	0	0	0	0	0	0	4374
ŞUBAT	1	14	0	1	0	0	0	0	0	0	0	0	0	0	4688
MART	1	15	0	0	1	0	0	0	0	0	0	0	0	0	4986
NİSAN	1	16	0	0	0	1	0	0	0	0	0	0	0	0	4986
MAYIS	1	17	0	0	0	0	1	0	0	0	0	0	0	0	4717
HAZİRAN	1	18	0	0	0	0	0	1	0	0	0	0	0	0	4435
TEMMUZ	1	19	0	0	0	0	0	0	1	0	0	0	0	0	3600
AĞUSTOS	1	20	0	0	0	0	0	0	0	1	0	0	0	0	4111
EYLÜL	1	21	0	0	0	0	0	0	0	0	1	0	0	0	8164
EKİM	1	22	0	0	0	0	0	0	0	0	0	1	0	0	3120
KASIM	1	23	0	0	0	0	0	0	0	0	0	0	1	0	8791
ARALIK	1	24	0	0	0	0	0	0	0	0	0	0	0	1	8791

4.1.2 Regresyon Analiz Eğitimi



Şekil 20 Excel Data Analysis Tool



Şekil 21 Excel Data Analysis Regression Panel

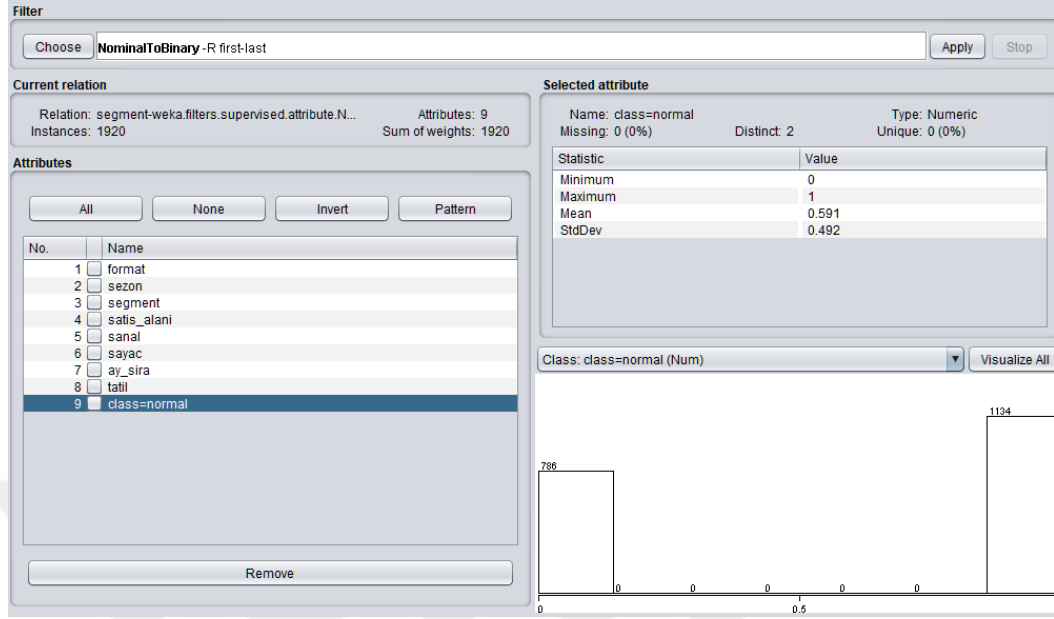
Tablo 14 Ay Trendi Bazında Regresyon Anlamlılık Değeri

SUMMARY OUTPUT	
<i>Regression Statistics</i>	
Multiple R	0,856613259
R Square	0,733786276
Adjusted R Square	0,443371304
Standard Error	1133,995103
Observations	24

Tablo 15 Trend Coefficients Deęerleri

	<i>Coefficients</i>
Intercept	6601,75
AY-SIRA	48,26388889
OCAK	-2449,097222
ŞUBAT	-2196,861111
MART	-2221,625
NİSAN	-1658,888889
MAYIS	-2439,652778
HAZİRAN	-3079,916667
TEMMUZ	-3142,680556
AĞUSTOS	-3461,944444
EYLÜL	-309,2083333
EKİM	-3603,472222
KASIM	-609,2361111

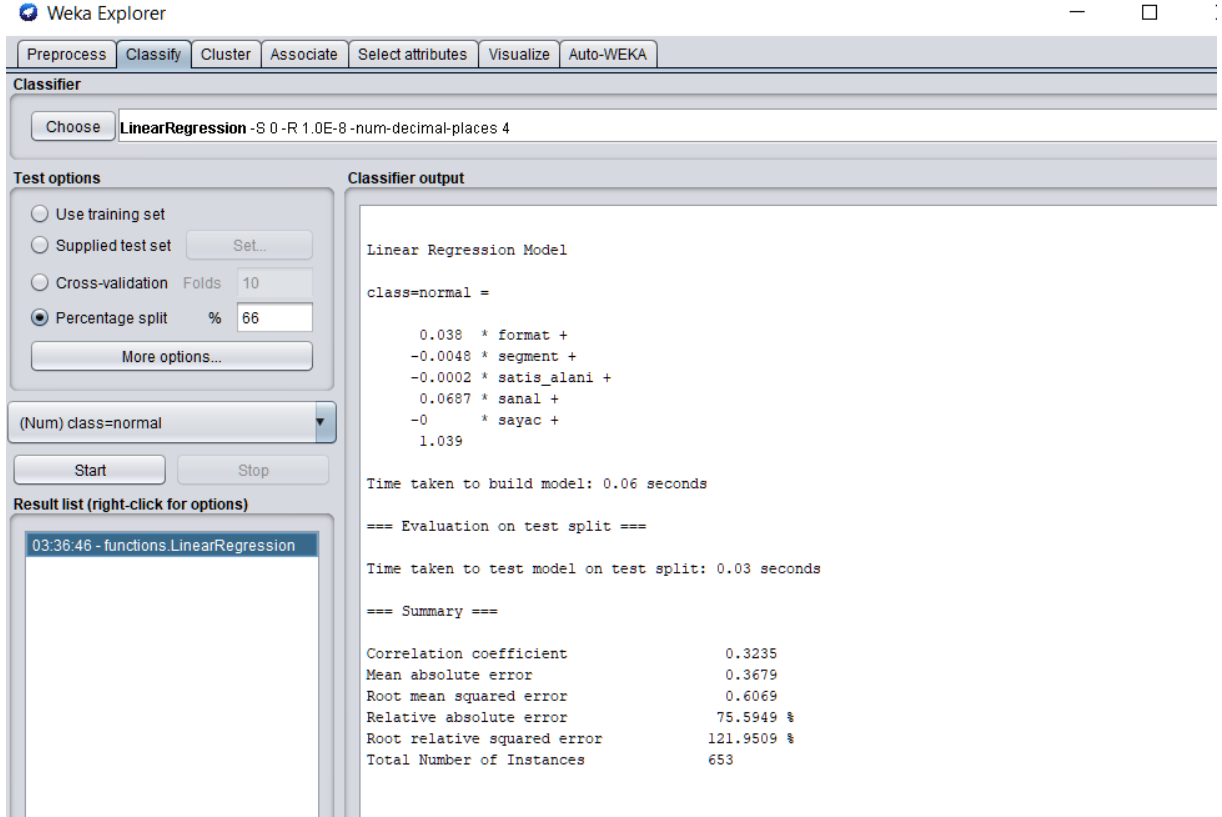
4.1.4 Eğitim Sonuçları



Şekil 22 Veri Seti Class Yapısı Nominal to Binary Filtre

4.1.5 Regresyon Analizi Sonuçları

WeKa üzerinde yapılan çalışma sonuçları Şekil 22 'de gösterildiği gibidir.



The screenshot shows the Weka Explorer interface. The 'Classifier' tab is selected, and 'LinearRegression -S 0-R 1.0E-8 -num-decimal-places 4' is chosen. The 'Test options' section shows 'Percentage split' selected with a value of 66%. The 'Classifier output' window displays the following results:

```
Linear Regression Model
class=normal =
  0.038 * format +
 -0.0048 * segment +
 -0.0002 * satis_alani +
  0.0687 * sanal +
 -0 * sayac +
  1.039

Time taken to build model: 0.06 seconds

=== Evaluation on test split ===

Time taken to test model on test split: 0.03 seconds

=== Summary ===

Correlation coefficient          0.3235
Mean absolute error             0.3679
Root mean squared error        0.6069
Relative absolute error         75.5949 %
Root relative squared error     121.9509 %
Total Number of Instances      653
```

Şekil 23 Lineer Regresyon Çıktısı

Şekil 22 'de de gösterildiği üzere, Regresyon uygulayabilmek için ilk önce verilerin tümünün sayısal veriler olduğunu kontrol etmek gereklidir. Aksi halde WeKa üzerinde “token hatası” ile karşılaşılır. Bu çevirimi WeKa üzerinden yapmam mümkündür. Eğitim seti program üzerine import edildikten sonra “filtreler” başlığı altından “unsupervised (gözetimsiz)” sekmesi içinden “nominal to binary” filtresi aracılığıyla ilgili parametreler “class dahil” dönüştürme işlemi uygulanabilmektedir.

Uygulama sonrası; class değerleri aşağıdaki şekilde dönüştürülmüştür.

- 0 = Overload
- 1 = Normal

```
==== Run information ====

Scheme:      weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -num-
decimal-places 4

Relation:      segment-weka.filters.supervised.attribute.NominalToBinary-
weka.filters.unsupervised.attribute.NominalToBinary-Rfirst-last

Instances:  1920

Attributes:  9

    format
    sezon
    segment
    satis_alani
    sanal
    sayac
    ay_sira
    tatil
    class=normal

Test mode:  split 66.0% train, remainder test

==== Classifier model (full training set) ====
```

Linear Regression Model

class=normal =

0.038 * format +
-0.0048 * segment +
-0.0002 * satis_alani +
0.0687 * sanal +
-0 * sayac +
1.039

Time taken to build model: 0.06 seconds

=== Predictions on test split ===

inst#	actual	predicted	error
1	0	0.441	0.441
2	0	0.199	0.199
3	0	0.52	0.52
4	1	0.562	-0.438
5	1	0.745	-0.255
6	1	0.63	-0.37
7	0	0.532	0.532

8	1	0.641	-0.359
9	1	0.652	-0.348
10	0	0.401	0.401
==== Evaluation on test split ====			
Time taken to test model on test split: 0.56 seconds			
==== Summary ====			
Correlation coefficient		0.3235	
Mean absolute error		0.3679	
Root mean squared error		0.6069	
Relative absolute error		75.5949 %	
Root relative squared error		121.9509 %	
Total Number of Instances		653	

Şekil 24 Regresyon Eğitim Çıktısı

4.1.6 Trend Analizi Sonuçları

Eğitim sonucunda karşılaştırmalı veriler Tablo 16 'da gösterildiği gibidir.

Tablo 16 24 Aylık Veri İle Takip Eden 12 Aylık Tahmin Veri Tablosu

DONEM	AY	AY-SIRA	GERCEK BASKI	TAHMIN BASKI	FARK	YUZDE FARK
2016	OCAK	1	4607	4201	406	-8,81%
2016	ŞUBAT	2	4894	4453	441	-9,01%
2016	MART	3	4643	4428	215	-4,62%
2016	NİSAN	4	5865	4991	874	-14,90%
2016	MAYIS	5	4669	4210	459	-9,82%
2016	HAZİRAN	6	3767	3570	197	-5,23%
2016	TEMMUZ	7	4573	3507	1066	-23,30%
2016	AĞUSTOS	8	3520	3188	332	-9,43%
2016	EYLÜL	9	5869	6341	-472	8,04%
2016	EKİM	10	4421	3047	1374	-31,09%
2016	KASIM	11	4835	6041	-1206	24,94%
2016	ARALIK	12	6150	6650	-500	8,13%
2018	OCAK	25	2877	5359	2482	86,28%
2018	ŞUBAT	26	4270	5660	1390	32,55%
2018	MART	27	4331	5683	1352	31,22%
2018	NİSAN	28	4320	6294	1974	45,70%
2018	MAYIS	29	5055	5562	507	10,02%
2018	HAZİRAN	30	4529	4970	441	9,73%
2018	TEMMUZ	31	3277	4955	1678	51,21%
2018	AĞUSTOS	32	5361	4684	-677	-12,62%
2018	EYLÜL	33	4317	7885	3568	82,66%
2018	EKİM	34	4771	4639	-132	-2,76%
2018	KASIM	35	2917	7682	4765	163,34%
2018	ARALIK	36	5355	8339	2984	55,73%

4.2 Yapay Zeka Tabanlı Yöntemler

4.2.1 Yapay Sinir Ağı Veri Seti

Tablo 12 'de gösterildiği gibi, WeKa üzerinde yapılacak eğitim için, daha küçük kapsamlı 1 aylık 80 farklı yazıcıdan gelen verilere istinaden 8 farklı parametre baz alınarak hazırlanmış eğitim seti bulunmaktadır.

Tablo 17 OCAK 2016 Yılı İçin Hazırlanmış Örnek Eğitim Data Seti

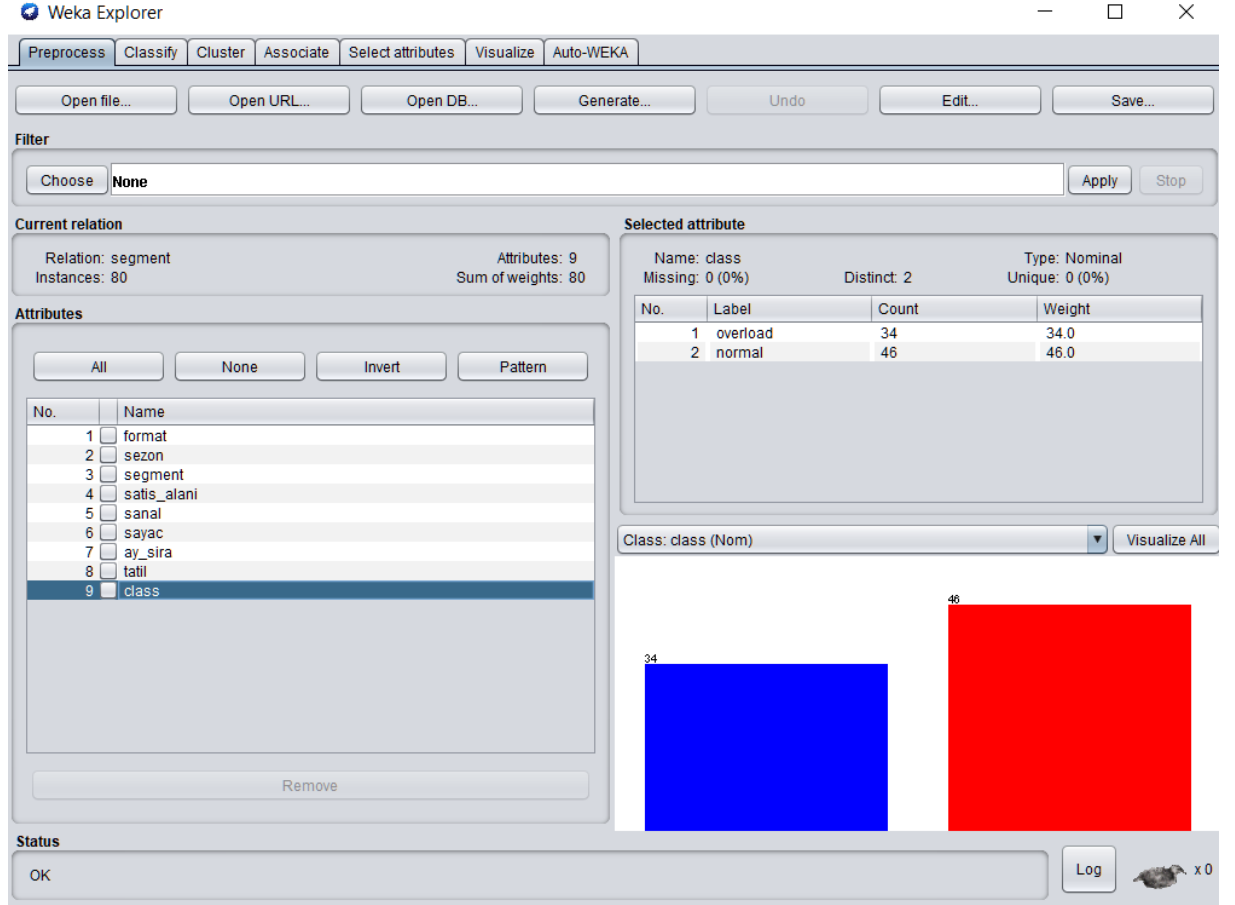
format	sezon	segment	satis_alani	sanal	sayac	ay_sira	tatil	sonuc
1	0	24	464	0	0	1	1	normal
1	0	22	415	0	0	1	1	normal
2	0	31	847	0	0	1	1	normal
2	0	21	972	0	0	1	1	normal
2	0	44	933	0	0	1	1	normal
3	0	42	1183	0	0	1	1	normal
1	0	21	383	0	1379	1	1	normal
2	0	44	1119	0	1381	1	1	normal
1	0	11	449	0	1609	1	1	normal
2	0	32	728	0	1690	1	1	normal
2	0	34	885	0	1760	1	1	normal
1	0	12	530	0	1800	1	1	normal
1	0	11	348	0	1831	1	1	normal
1	0	44	409	0	1951	1	1	normal
1	0	21	423	0	1959	1	1	normal
1	0	31	287	0	1978	1	1	normal
1	0	12	482	0	1988	1	1	normal
2	0	34	786	0	2029	1	1	normal
1	0	21	250	0	2096	1	1	normal
1	0	21	445	0	2123	1	1	normal
2	0	44	1296	0	2183	1	1	normal
2	0	44	947	0	2187	1	1	normal
3	0	41	1972	0	2303	1	1	normal
1	0	21	330	0	2372	1	1	normal
2	0	44	772	0	2418	1	1	normal
2	0	44	1346	0	2453	1	1	normal
1	0	12	406	0	2479	1	1	normal
1	0	22	559	0	2546	1	1	normal
2	0	32	1100	1	2560	1	1	normal
1	0	21	437	0	2572	1	1	normal
1	0	21	640	0	2601	1	1	normal
2	0	34	752	0	2603	1	1	normal
1	0	21	452	0	2611	1	1	normal
2	0	42	1366	0	2623	1	1	normal
1	0	22	550	0	2659	1	1	normal
2	0	32	705	0	2689	1	1	normal
2	0	31	782	0	2723	1	1	normal
1	0	21	530	0	2767	1	1	normal
1	0	21	568	0	2803	1	1	normal
2	0	31	1206	0	2838	1	1	normal
1	0	44	595	0	2859	1	1	normal
2	0	32	667	0	2873	1	1	normal
2	0	32	755	0	2899	1	1	normal
3	0	41	1787	1	2911	1	1	normal

1	0	21	550	0	2967	1	1	normal
2	0	31	843	0	2976	1	1	normal
1	0	44	350	0	3023	1	1	overload
2	0	44	994	0	3042	1	1	overload
2	0	31	1360	0	3061	1	1	overload
1	0	22	507	0	3104	1	1	overload
5	0	2	3815	1	3165	1	1	overload
1	0	12	362	0	3184	1	1	overload
2	0	31	832	0	3187	1	1	overload
2	0	44	1036	0	3239	1	1	overload
2	0	21	1051	0	3267	1	1	overload
2	0	31	1108	0	3444	1	1	overload
3	0	42	1530	1	3590	1	1	overload
2	0	31	705	0	3600	1	1	overload
3	0	44	1380	0	3650	1	1	overload
2	0	31	1323	0	3652	1	1	overload
2	0	31	1056	0	3666	1	1	overload
3	0	44	1417	0	3716	1	1	overload
2	0	31	1171	0	3748	1	1	overload
2	0	22	1480	0	3772	1	1	overload
2	0	41	1527	0	3810	1	1	overload
2	0	32	1038	0	3891	1	1	overload
3	0	42	2101	1	4150	1	1	overload
3	0	44	1560	0	4213	1	1	overload
3	0	31	1720	0	4214	1	1	overload
3	0	43	2238	0	4401	1	1	overload
3	0	31	2072	0	4513	1	1	overload
3	0	43	1900	1	4607	1	1	overload
1	0	21	673	0	4609	1	1	overload
2	0	32	1217	0	4832	1	1	overload
2	0	31	1329	0	5178	1	1	overload
3	0	42	1795	0	5881	1	1	overload
3	0	42	1498	1	6146	1	1	overload
3	0	32	1977	1	6162	1	1	overload
1	0	22	598	0	8929	1	1	overload
2	0	31	887	0	44821	1	1	overload

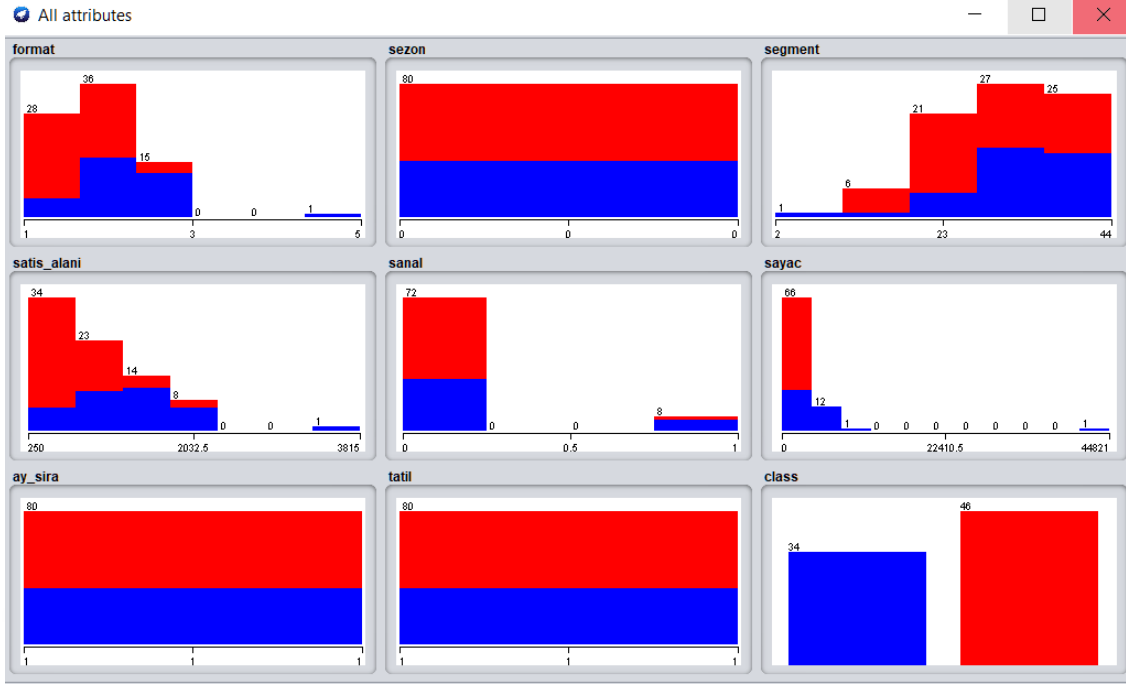
Tablo 18 OCAK 2016 Yılı İçin Hazırlanmış Örnek Eğitim Data Seti (devamı)

Hesaplamlarda kullanılmak amacıyla seçilen yazıcının baskı hacmi dikkate alındığında aylık ortalama 3000 (üç bin) adetlik bir baskı hacmine sahiptir. Bu nedenle veri seti üzerinde algoritmanın eğitilmesinde de bu detay eğitim setine dahil edilmiştir.

3000 adet ve üzeri aylık baskı miktarı çalışma için overload yani kırılım değeri olarak işlem görmektedir. Bu adedin altında kalan baskı hacmi “normal” olarak kabul edilerek hesaplamalara dahil edilmiştir.



Şekil 25 YSA Veri Seti Parametre Ve Sınıf Dağılımı



Şekil 26 YSA Eğitim Seti Parametre Dağılımı

4.2.2 Yapay Sinir Ağının Eğitimi

Tablo 19 'de yer alan veri seti YSA öğrenmesine uygun olacak şekilde düzenlenmiştir.

4.2.3 Yapay Sinir Ağı Modelin Çalışma Yapısı

Multilayer Perceptron çalışmasına uygun veri seti hazırlandıktan sonra tüm parametre ve class tanımlamaları yapılmıştır. Detaylara Tablo 19 'dan ulaşılabilmektedir.

Tablo 19 Çok Katmanlı Algılayıcı (MLP) İçin Hazırlanan Veri Seti

@relation segment

@attribute format numeric

@attribute sezon numeric

@attribute segment numeric

@attribute satis_alani numeric

@attribute sanal numeric

@attribute sayac numeric

@attribute ay_sira numeric

@attribute tatil numeric

@attribute class {overload,normal}

@data

1,0,24,464,0,0,1,1,normal

1,0,22,415,0,0,1,1,normal

2,0,31,847,0,0,1,1,normal

2,0,21,972,0,0,1,1,normal

2,0,44,933,0,0,1,1,normal

3,0,42,1183,0,0,1,1,normal

1,0,21,383,0,1379,1,1,normal

2,0,44,1119,0,1381,1,1,normal

1,0,11,449,0,1609,1,1,normal

2,0,32,728,0,1690,1,1,normal

2,0,34,885,0,1760,1,1,normal
1,0,12,530,0,1800,1,1,normal
1,0,11,348,0,1831,1,1,normal
1,0,44,409,0,1951,1,1,normal
1,0,21,423,0,1959,1,1,normal
1,0,31,287,0,1978,1,1,normal
1,0,12,482,0,1988,1,1,normal
2,0,34,786,0,2029,1,1,normal
1,0,21,250,0,2096,1,1,normal
1,0,21,445,0,2123,1,1,normal
2,0,44,1296,0,2183,1,1,normal
2,0,44,947,0,2187,1,1,normal
3,0,41,1972,0,2303,1,1,normal
1,0,21,330,0,2372,1,1,normal
2,0,44,772,0,2418,1,1,normal
2,0,44,1346,0,2453,1,1,normal
1,0,12,406,0,2479,1,1,normal
1,0,22,559,0,2546,1,1,normal
2,0,32,1100,1,2560,1,1,normal
1,0,21,437,0,2572,1,1,normal
1,0,21,640,0,2601,1,1,normal
2,0,34,752,0,2603,1,1,normal
1,0,21,452,0,2611,1,1,normal
2,0,42,1366,0,2623,1,1,normal

1,0,22,550,0,2659,1,1,normal
2,0,32,705,0,2689,1,1,normal
2,0,31,782,0,2723,1,1,normal
1,0,21,530,0,2767,1,1,normal
1,0,21,568,0,2803,1,1,normal
2,0,31,1206,0,2838,1,1,normal
1,0,44,595,0,2859,1,1,normal
2,0,32,667,0,2873,1,1,normal
2,0,32,755,0,2899,1,1,normal
3,0,41,1787,1,2911,1,1,normal
1,0,21,550,0,2967,1,1,normal
2,0,31,843,0,2976,1,1,normal
1,0,44,350,0,3023,1,1,overload
2,0,44,994,0,3042,1,1,overload
2,0,31,1360,0,3061,1,1,overload
1,0,22,507,0,3104,1,1,overload
5,0,2,3815,1,3165,1,1,overload
1,0,12,362,0,3184,1,1,overload
2,0,31,832,0,3187,1,1,overload
2,0,44,1036,0,3239,1,1,overload
2,0,21,1051,0,3267,1,1,overload
2,0,31,1108,0,3444,1,1,overload
3,0,42,1530,1,3590,1,1,overload
2,0,31,705,0,3600,1,1,overload

3,0,44,1380,0,3650,1,1,overload
2,0,31,1323,0,3652,1,1,overload
2,0,31,1056,0,3666,1,1,overload
3,0,44,1417,0,3716,1,1,overload
2,0,31,1171,0,3748,1,1,overload
2,0,22,1480,0,3772,1,1,overload
2,0,41,1527,0,3810,1,1,overload
2,0,32,1038,0,3891,1,1,overload
3,0,42,2101,1,4150,1,1,overload
3,0,44,1560,0,4213,1,1,overload
3,0,31,1720,0,4214,1,1,overload
3,0,43,2238,0,4401,1,1,overload
3,0,31,2072,0,4513,1,1,overload
3,0,43,1900,1,4607,1,1,overload
1,0,21,673,0,4609,1,1,overload
2,0,32,1217,0,4832,1,1,overload
2,0,31,1329,0,5178,1,1,overload
3,0,42,1795,0,5881,1,1,overload
3,0,42,1498,1,6146,1,1,overload
3,0,32,1977,1,6162,1,1,overload
1,0,22,598,0,8929,1,1,overload
2,0,31,887,0,44821,1,1,overload

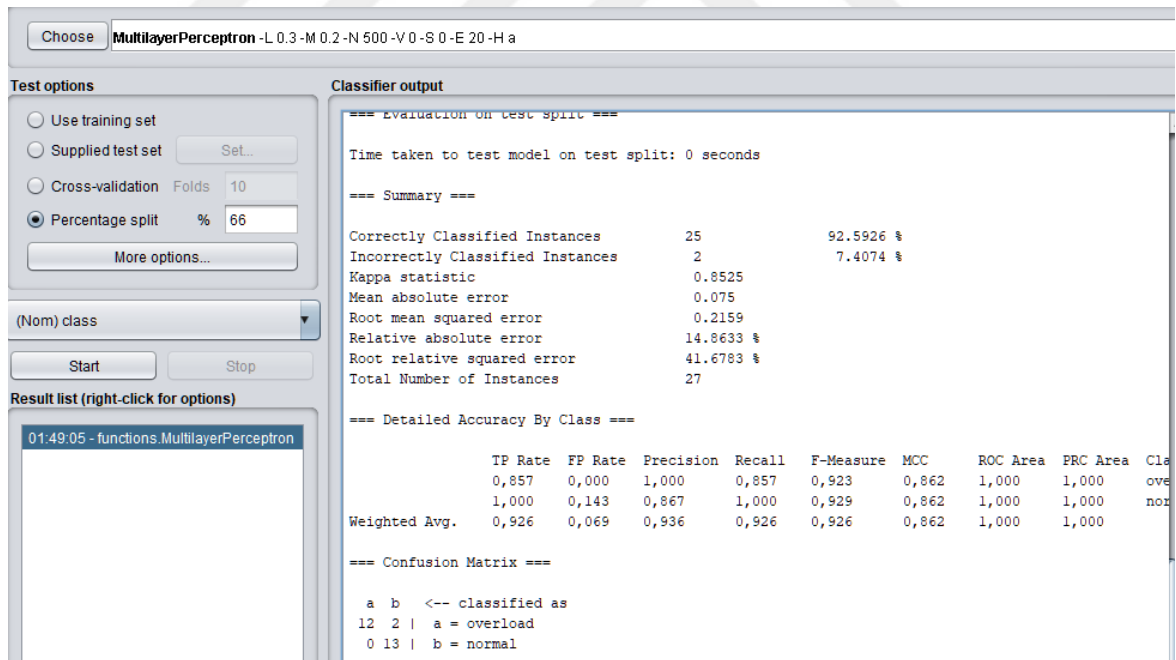
4.2.4 Yapay Sinir Ağı Eğitim Sonuçları

MLP algoritmasında hesaplama yapmak için 2 farklı örnek kullanılmıştır. Bunlardan 1. Si 80 adetlik OCAK 2016 verisine sahip bir veri setidir. Bu çalışma sonucu Şekil 26 'da gösterildiği gibidir.

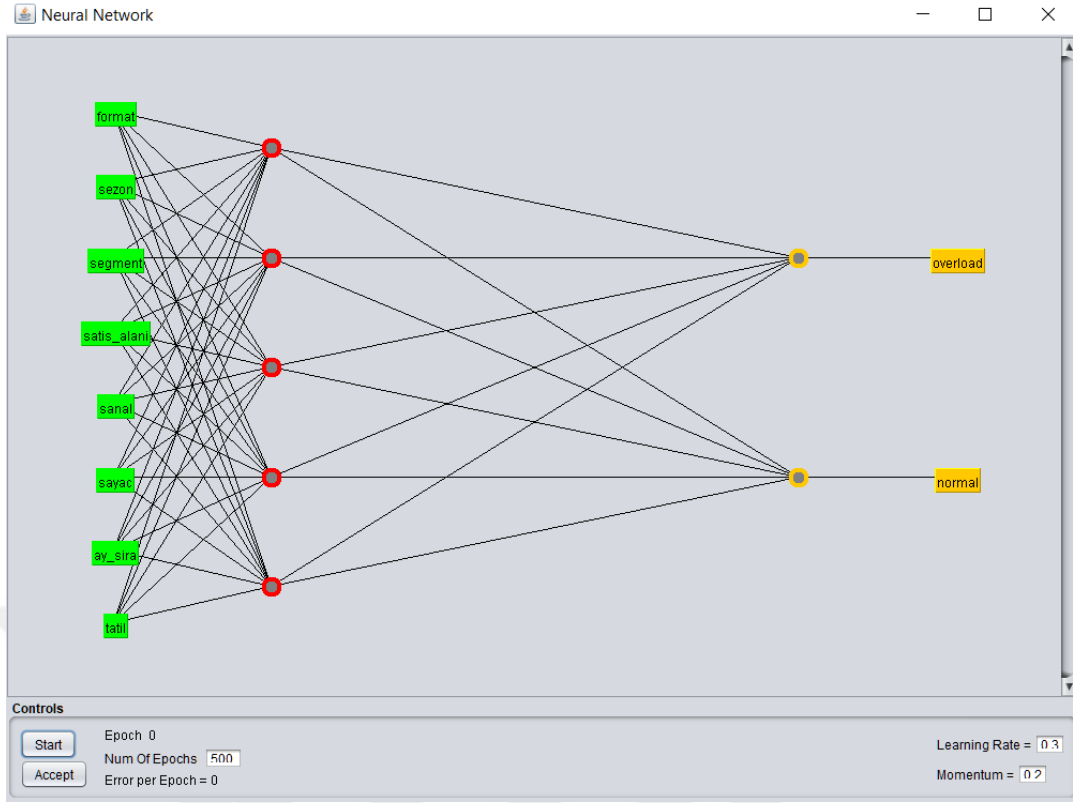
4.2.5 Multilayer Perceptron Sonuçları

Şekil 24 'te paylaşılan 80 adetlik veri seti öğrenmesi sonucunda %92 'nin üzerinden bir başarı elde edilmiştir.

Bunda veri setinin temiz oluşu en büyük etken olarak göz önünde bulundurulmalıdır. Ancak tüm bunlara rağmen MLP oldukça başarılı bir yöntem olarak kullanılabilir.

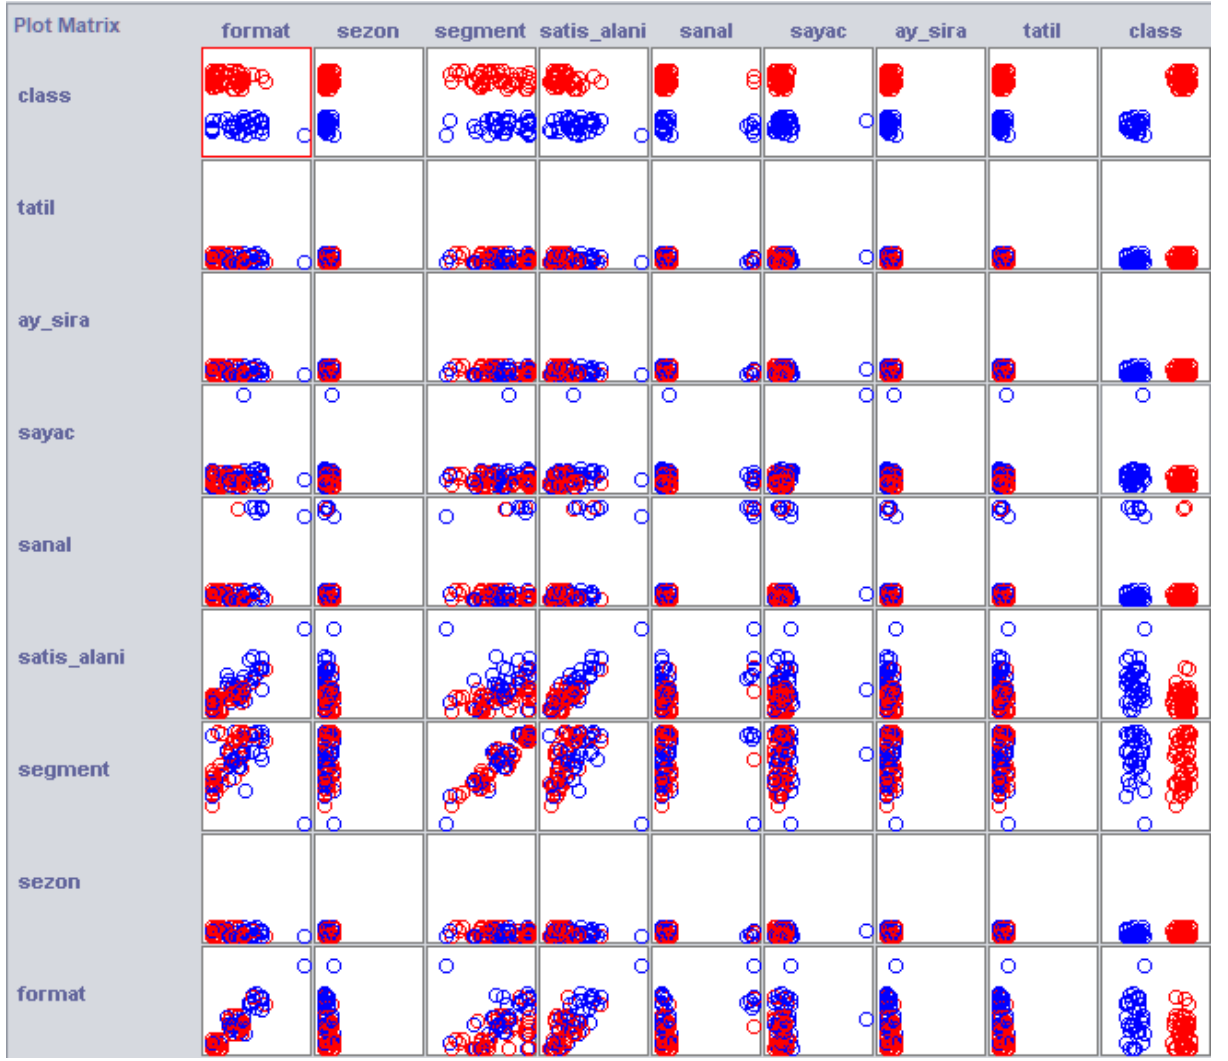


Şekil 27 MLP Çıktısı



Şekil 28 Multi Layer Perceptron Kullanılarak Oluşturulan Ağ

Şekil 28 'de paylaşıldığı gibi, MLP kullanılarak oluşturulan ağ şeması gösterildiği gibidir.

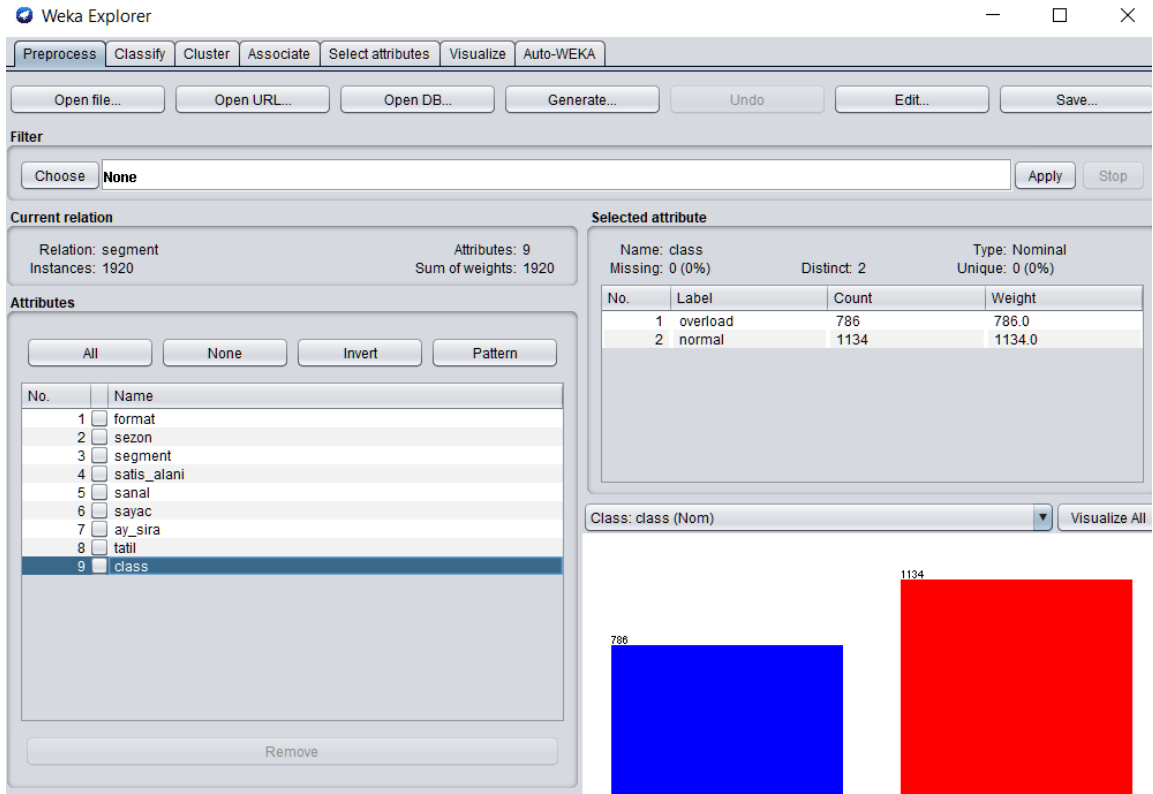


Şekil 29 MLP Sonucu Oluşan Plot Matrix

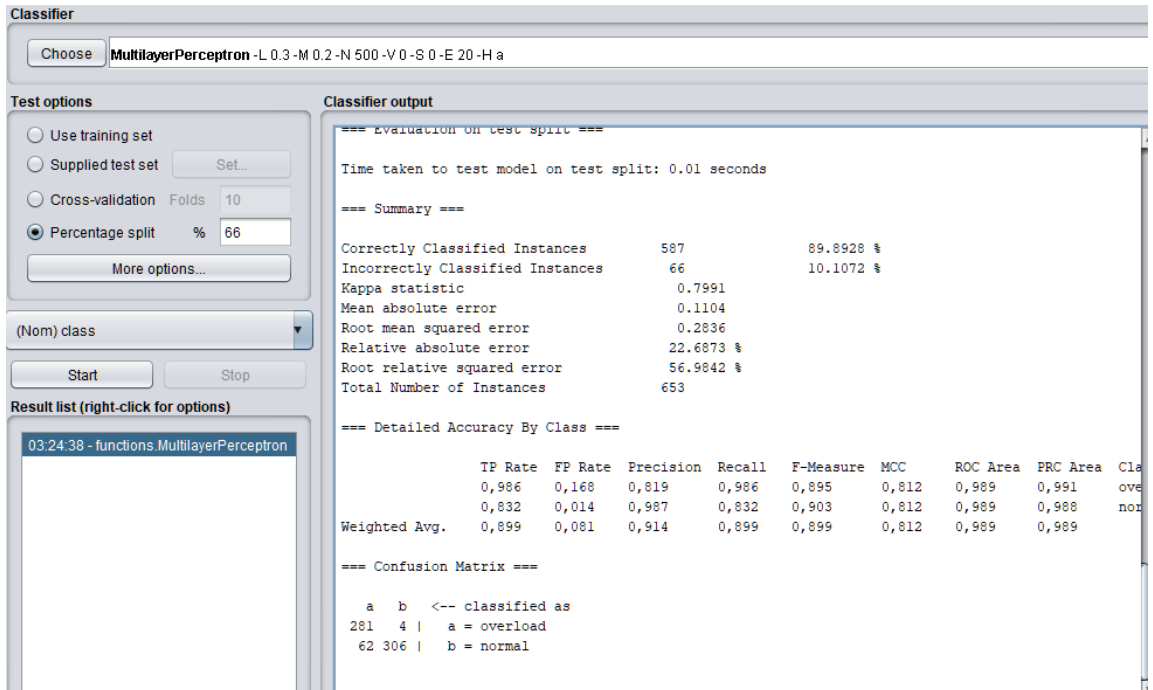
Şekil 28 'de MLP sonucunda oluşan Plot Matrix tablosu gösterildiği gibidir.

Kırmızı = Normal


Mavi = Overload



Şekil 30 YSA Veri Seti Parametre Ve Sınıf Dağılımı (2. Örnek)



Şekil 31 YSA Eğitim Sonucu (2. Örnek)



Şekil 32 MLP Sonucu Oluşan Sinir Ağı (2. Örnek)

4.2.6 Naive Bayes Sonuçları

MLP çalışmasına ek olarak diğer bir başarılı yöntem olan Naive Bayes ile veri seti işleme tabi tutulmuştur.

Buradaki başarı oranı %81 olarak gözlenmiştir.

Weka Explorer

Preprocess Classify Cluster Associate Select attributes Visualize Auto-WEKA

Classifier: Choose NaiveBayes

Test options

Use training set
 Supplied test set (Set...)
 Cross-validation Folds 10
 Percentage split % 66
 More options...

(Nom) class

Start Stop

Result list (right-click for options)

- 01:49:05 - functions.MultilayerPerceptron
- 02:19:09 - functions.MultilayerPerceptron
- 02:26:06 - bayes.NaiveBayes

Classifier output

```

Time taken to build model: 0 seconds

=== Evaluation on test split ===

Time taken to test model on test split: 0 seconds

=== Summary ===

Correctly Classified Instances      22      81.4815 %
Incorrectly Classified Instances    5       18.5185 %
Kappa statistic                    0.6322
Mean absolute error                 0.243
Root mean squared error             0.3932
Relative absolute error             48.1843 %
Root relative squared error         75.9118 %
Total Number of Instances          27

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area
                0,714   0,077   0,909     0,714   0,800     0,648   0,879   0,917
                0,923   0,286   0,750     0,923   0,828     0,648   0,879   0,864
Weighted Avg.   0,815   0,177   0,832     0,815   0,813     0,648   0,879   0,891

=== Confusion Matrix ===

 a b  <-- classified as
10 4 | a = overload
 1 12 | b = normal
  
```

Status

OK Log x 0

Şekil 33 Naive Bayes Çıktısı

Classifier

Choose **NaiveBayes**

Test options

Use training set
 Supplied test set
 Cross-validation Folds
 Percentage split %

(Nom) class

Result list (right-click for options)

03:24:38 - functions.MultilayerPerceptron
03:27:08 - functions.MultilayerPerceptron
03:29:08 - bayes.NaiveBayes

Classifier output

```

=== Evaluation on test split ===

Time taken to test model on test split: 0.01 seconds

=== Summary ===

Correctly Classified Instances      557      85.2986 %
Incorrectly Classified Instances    96       14.7014 %
Kappa statistic                    0.6963
Mean absolute error                 0.2219
Root mean squared error             0.3348
Relative absolute error             45.581 %
Root relative squared error        67.277 %
Total Number of Instances          653

=== Detailed Accuracy By Class ===

                TP Rate  FP Rate  Precision  Recall  F-Measure  MCC      ROC Area  PRC Area  Cla
0,761  0,076  0,886  0,761  0,819  0,702  0,906  0,912  ove
0,924  0,239  0,833  0,924  0,876  0,702  0,906  0,888  nor
Weighted Avg.  0,853  0,168  0,856  0,853  0,851  0,702  0,906  0,898

=== Confusion Matrix ===

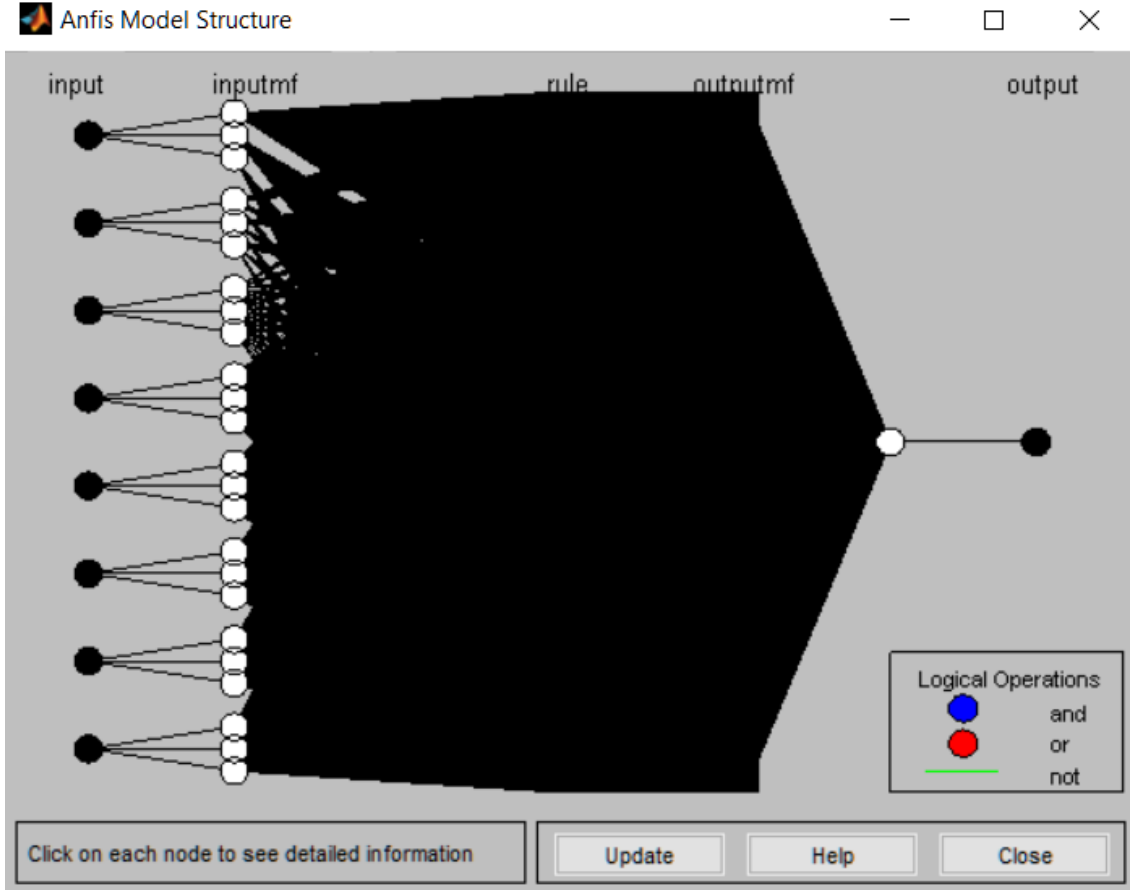
  a  b  <-- classified as
217 68 | a = overload
 28 340 | b = normal

```

Şekil 34 Naive Bayes Çıktısı (2. Örnek)

4.2.7 ANFIS Sonuçları

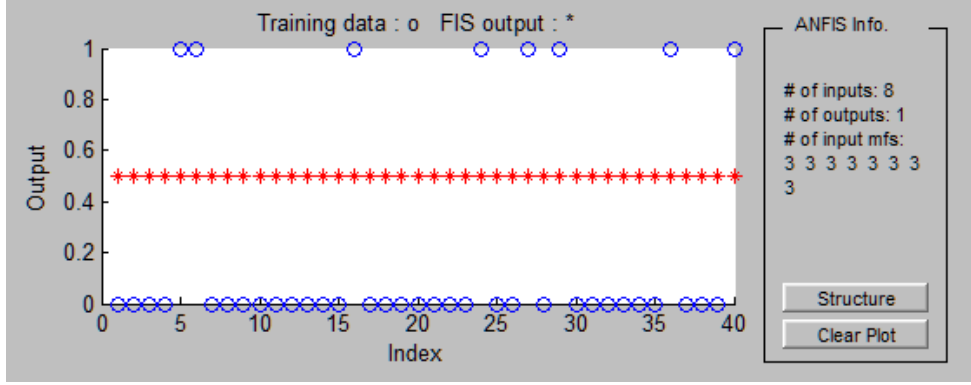
Şekil 37 'te gösterildiği gibi aynı veri seti ile MATLAB üzerinde yapılan çalışma



Şekil 35 ANFIS Ağ Yapısı

Diğer çalışmalara ek olarak diğer bir başarılı yöntem olan ANFIS ile veri seti işleme tabi tutulmuştur.

Buradaki başarı oranı %84 olarak gözlenmiştir.



Şekil 36 ANFIS Sonucu

BEŞİNCİ BÖLÜM

5. SONUÇ

Dışarıdan her ne kadar basit cihazlar olarak görüsel de yazıcılar büyük ölçekli firmalar için oldukça büyük bir gider kalemi oluşturmaktadır. Baskı çözümü üreten firmalar, bu donanım ve hizmeti sağlarken günümüzde çok daha fazla noktaya özellikle teknolojilere ve güvenli baskı çözümlerine dikkat etmek durumundalardır.

Bu hizmeti alan firmalar ise karşılıklı güven çerçevesinde SLA, diğer bir adıyla Service-level agreement yani verilen servisin kalitesi, sürdürülebilirliği, takibi vb. Birçok konuyu ele alarak değerlendirilmektedir. Aksi halde ortaya çok profesyonel olmayan bir iş akış şemasının ortaya çıkması muhtemeldir.

Hizmeti sağlayan ve talep eden taraflar arasında 2 türlü anlaşma yapılabilmektedir.

Bunlardan ilki, tüm maliyetlerin anlık olarak hizmeti alan firmaya yansıtılarak yani bireysel kullanıcı nasıl bir hizmet alıyor ise aynı şekilde düşünülebilir.

Bunlardan ikincisi ise, hiçbir ek beden ödenmeden “sayfa başı” ödeme sistemidir. Bu sistemde hizmeti alan firma toner, kağıt, bakım masrafı gibi hiçbir ücret ile karşılaşmaz. Aylık periyodlar halinde hakediş adı verilen raporlar yayınlanır. Bu raporlarda çalışmada da sıkça bahsedilen “sayaç, diğer bir adıyla yazıcı kilometre değeri” rapor edilir. Bu hizmeti alan firma tarafından kontrol edilerek hizmet sağlayıcısına ödenir.

Yapılan çalışmada görülmüştür ki baskı durumunu ay, değeri yani dönemsellik etkiliyor. Ancak bunun dışında resmi tatil ve format parametresi de etki oranı yüksek diğer etmelerdir. Yani geçmiş verileri baz alarak geleceğe ait çıkarımlarda bulunmak mümkündür. 2016-2017 verileri kullanılarak tahmin edilen 2018 yılına ait veriler gerçek veriler ile karşılaştırıldığında modelin Regresyon Analizi ile %73 oranında anlamlılık derecesi olduğu gözlemlenmiştir.

Ek olarak çalışmada, baskı adetlerini etkilen faktörler 8 farklı parametre olarak tanımlanmıştır. Bu metrikler algoritmalara dahil edilerek yapılan hesaplamalar sonucu, Multilayer Perceptron, Naive Bayes ve ANFIS ‘e göre daha yüksek bir oranla öne çıkmıştır.

Bu bağlamda yapılan çalışmadaki başarı durumları aşağıdaki gibidir:

Excel Regresyon Analizi	: %73
WeKa Regresyon Analizi	: %32
Multilayer Perceptron	: %89 ile %92 arasında
Naive Bayes	: %81 ile % 85 arasında
ANFIS	: %84



KAYNAKÇA

Kitaplar

Üretim Planlama ve Kontrol / Tanyaş, Mehmet ; Murat Baskak.

Geleceği Tahmin Yöntemleri / ÖZMUCUR , Süleyman.

Diğer Yayınlar

<http://kod5.org/basit-ag-yonetim-protokolu-snmp-nedir/>

(Erişim Tarihi: 03.02.2019)

https://gerardnico.com/data_mining/shrinkage

(Erişim Tarihi: 01.05.2019)

İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu İle Ürün Talep Tahmini Uygulaması, Mehmet Karahan

- [1] Karahan, M., (2011), İstatistiksel Tahin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması, Doktora Tezi, Selçuk Üniversitesi Sosyal Bilimler Enstitüsü, Konya.
- [2] Çağlar, T.,(2007). Talep Tahmininde Kullanılan Yöntemler ve Fens Teli ÜretimiYapan Bir İşletmede Uygulanması, Yüksek Lisans Tezi, Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Kırıkkale.
- [3] Kirby, H.R., Watson, S.M. ve Dougherty, M.S. (1997). “Should We Use Neural Networks or Statistical Models For Short-Term Motorway TrafficForecasting?”, International Journal Of Forecasting,13: 43-50.
- [4] Gürbüz, T., (2008). Yapay Sinir Ağları Yaklaşımıyla Türkiye’deki Ulaştırma Talebinin Tahmini, Yüksek Lisans Tezi, Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü, Kırıkkale.
- [5] Yüksek, A. G., (2007). Hava Kirliliği Tahmininde Yapay Sinir Ağları ve Çoklu Regresyon, Doktora Tezi, Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas.
- [6] Ataseven, B., (2007). Satış Öngörü Modellemesi Olarak Yapay Sinir Ağlarının Kullanımı: PETKİM’de Uygulanması, Yüksek Lisans Tezi, Celal Bayar Üniversitesi Sosyal Bilimler Enstitüsü, Manisa.
- [7] Çelik, B., (2008). Yapay Sinir Ağları Metodolojisi ile Zaman Serisi Analizi: Teori ve Uygulama, Yüksek Lisans Tezi, Marmara Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- [8] Asilkan, Ö. ve Irmak, S. (2009). “İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi”, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14(2): 375-391.

- [9] Tanyaş, M. ve Baskak, M., (2008), Üretim Planlama ve Kontrol, 3. Baskı, İrfan Yayıncılık, İstanbul.
- [10] Üreten, S. (2005). Üretim/İşlemler Yönetimi, Stratejik Kararlar ve Karar Modelleri, 5. Baskı, Gazi Kitabevi, Ankara.
- [11] Monks, J.G. (1996), İşlemler Yönetimi Teori ve Problemler, (Çeviren: Sevinç Üreten) Nobel Yayın Dağıtım, Ankara.
- [12] Efendigil, T., (2008). Müşteri Odaklı Sistemler için Yapay Sinir Ağları ve Bulanık Çıkarım Tabanlı Karar Destek Sistemi Yaklaşımı, Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [13] Ergün, M. E., (2008). Sermaye Bütçelemesi ve Türk Sanayi İşletmelerinde Uygulaması, Yüksek Lisans Tezi, Çukurova Üniversitesi Sosyal Bilimler Enstitüsü, Adana.
- [14] Tekin, M., (2009). Üretim Yönetimi Cilt 1, 6. Baskı, Günay Ofset, Konya.
- [15] Kobu, B. (1994). Üretim Yönetimi, Avcıol Basım-Yayım, 8. Baskı, İstanbul.
- [16] Adıyaman, F., (2007). Talep Tahmininde Yapay Sinir Ağlarının Kullanılması, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [17] Meydan, Y.A., (2007), Talep Tahmin Yöntemleri ve Orta Ölçekli Bir İşletmede Uygulanması, Yüksek Lisans Tezi, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [18] Kurşun, S., (2007), Tekstil Endüstrisinde Benzetim Tekniği ile Üretim Hattı Modellemesi ve Uygun İş Akış Stratejisinin Belirlenmesi, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [19] İpek, M., (1995). Tam Zamanında Üretim Sistemi ve Bir Simülasyon Uygulaması, Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- [20] Öztemel, E. (2012). Yapay Sinir Ağları, 2. Baskı, Papatya Yayıncılık, İstanbul.
- [21] Güngör, E., (2007). Yapay Sinir Ağları Yardımı ile Makine Arızalarının Önceden Tahmin Edilmesi, Yüksek Lisans Tezi, Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü, Kocaeli.
- [22] Toktaş, İ. ve Aktürk, N., (2004). Makine Tasarım İşleminde Kullanılan Yapay Zeka Teknikleri ve Uygulama Alanları, Makine Teknolojileri Elektronik Dergisi, 2: 7-20.
- [23] Whitby, B., (2005). Yapay Zeka Yeni Başlayanlar İçin Kılavuz (Çeviren: Çiğdem Karabağlı), İletişim Yayınları, İstanbul.

- [24] Haykin, S., (1999). Neural Networks: A Comprehensive Foundation, Prentice- Hall, Second Edition, New Jersey.
- [25] Kohonen, T., Barna, G., (1987). Statistical Pattern Recognition with Neural Networks: Benchmarking Studies, Proc. of The İnt. Joint Conf. on Neural Networks, 1: 1-66
- [26] Stergiou, C. ve Siganos, D. (2010), Neural Networks, http://www.doc.ic.ac.uk/~nd/surprise_96/journal/vol4/cs11/report.html, 04 Mayıs 2019.
- [27] Saygılı, Y. S., (2008). İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülenmesi, Yüksek Lisans Tezi, Kara Harp Okulu Savunma Bilimleri Enstitüsü, Ankara.



ÖZGEÇMİŞ

1990 yılında İstanbul 'da doğdu. İstanbul Üsküdar Çengelköy Lisesi Türkçe-Matematik öğrenimini bitirdikten sonra Beykent Üniversitesi 'nde Yönetim Bilişim Sistemleri alanında lisansını tamamladı. Kariyer hayatına kurumsal iş tecrübesi olarak perakende sektöründe bir şirkette Bilgi Teknolojileri alanında başlamış olup aktif olarak devam etmektedir.

Turhan Gürhan KUTLU