

**T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ**



**YAPAY SİNİR AĞI TEKNİKLERİ KULLANARAK EĞİTİM YAYINCILIĞI
SEKTÖRÜNDE VERİ MADENCİLİĞİ**

YÜKSEK LİSANS TEZİ

Ayhan Yangın

**Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisliği Programı**

MART 2017

T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ



YAPAY SİNİR AĞI TEKNİKLERİ KULLANARAK EĞİTİM YAYINCILIĞI
SEKTÖRÜNDE VERİ MADENCİLİĞİ

YÜKSEK LİSANS TEZİ

Ayhan Yangın

Bilgisayar Mühendisliği Anabilim Dalı
Bilgisayar Mühendisli Programı

Danışman: Yrd.Doç.Dr. Metin ZONTUL

MART 2017



T.C.
İSTANBUL AYDIN ÜNİVERSİTESİ
FEN BİLİMLER ENSTİTÜSÜ MÜDÜRLÜĞÜ

Yüksek Lisans Tez Onay Belgesi

Enstitümüz Bilgisayar Mühendisliği Ana Bilim Dalı Bilgisayar Mühendisliği Tezli Yüksek Lisans Programı Y1313.010006 numaralı öğrencisi **Ayhan YANGIN**'in "YAPAY SİNİR AĞI TEKNİKLERİ KULLANARAK EĞİTİM YAYINCILIĞI SEKTÖRÜNDE VERİ MADENCİLİĞİ" adlı tez çalışması Enstitümüz Yönetim Kurulunun 31.01.2017 tarih ve 2017/03 sayılı kararıyla oluşturulan jüri tarafından **başarılı** ile Tezli Yüksek Lisans tezi olarak **onay** edilmiştir.

Öğretim Üyesi Adı Soyadı

İmzası

Tez Savunma Tarihi : 15.03.2017

1) Tez Danışmanı: Yrd. Doç. Dr. Metin ZONTUL

Metin Zontul

2) Jüri Üyesi : Prof. Dr. Zafer ASLAN

Zafer Aslan

3) Jüri Üyesi : Yrd. Doç. Dr. Ferdi SÖNMEZ

Ferdi Sönmez

Not: Öğrencinin Tez savunmasında **Başarılı** olması halinde bu form **imzalanacaktır**. Aksi halde geçersizdir.

YEMİN METNİ

Yüksek Lisans tezi olarak sunduğum “ **YAPAY SİNİR AĞI TEKNİKLERİ İLE EĞİTİM YAYINCILIĞI SEKTÖRÜNDE VERİ MADENCİLİĞİ**” adlı çalışmamın, tezin proje safhasından sonuçlanmasına kadarki bütün süreçlerde bilimsel ahlak ve geleneklere aykırı düşecek bir yardıma başvurulmaksızın yazıldığını ve yararlandığım eserlerin Bibliyografya’da gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanmış olduğumu belirtir ve onurumla beyan ederim. (15/03/2017)

Ayhan YANGIN



Eşime, Canım Annem ve Babama,





ÖNSÖZ

Bu çalışma, İstanbul Aydın Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalı Yüksek Lisans Tezi olarak hazırlanan “YAPAY SİNİR AĞI TEKNİKLERİ KULLANARAK EĞİTİM YAYINCILIĞI SEKTÖRÜNDE VERİ MADENCİLĞİ” isimli tezi içermektedir. Çalışmalarımın her aşamasında bilgi ve deneyimleri ile yardımcı olan kendisinden çok şey öğrendiğim, karşılaştığım problemlerde özgün fikirlerinden çokça istifade ettiğim danışmanım Sayın Yrd. Doç. Dr. Metin Zontul'a teşekkür ederim.

MART 2017

Ayhan Yangın



İÇİNDEKİLER

Sayfa

ÖNSÖZ.....	ix
İÇİNDEKİLER.....	xi
KISALTMALAR	xiii
ÇİZELGE LİSTESİ	xv
ŞEKİL LİSTESİ	xvii
ÖZET	xix
ABSTRACT	xxi
1. GİRİŞ.....	1
2. LİTERATÜR ÇALIŞMASI	3
3. YAPAY SİNİR AĞLARI.....	9
3.1 Yapay Sinir Ağları Nedir?	11
3.2 Yapay Sinir Ağları Genel Özellikleri.	11
3.3 Yapay Sinir Ağları'nın Kısa Tarihçesi.	13
3.4 Yapay Sinir Ağlarının Avantajları.	15
3.5 Yapay Sinir Ağlarının Dezavantajları.	15
3.6 Yapay Sinir Ağlarının Yapısı.	16
3.7 Yapay Sinir Ağlarının Sınıflandırılması.	20
3.7.1 İleri Beslemeli Yapay Sinir Ağları.....	21
3.7.2 Geri Beslemeli Yapay Sinir Ağları	21
3.8 Uygulamada Kullanılan Yöntemler.	22
3.8.1 Geri Yayılım Algoritması	25
4. VERİ MADENCİLİĞİ	29
4.1 Veri Madenciliği Nedir.	30
4.2 Kısaca Veri Madenciliği Tarihçesi.	29
4.3 Veri Madenciliği Sisteminin Sınıflandırılması ve Uygulama Alanları.....	29
4.4 Veri Madenciliği Bilgi Keşif Sürecinin Aşamaları.	31
4.5 Veri Madenciliği Modelleri.	31
5. TALEP TAHMİNİ VE TAHMİN YÖNTEMLERİ.....	37
5.1 Talep Tahminin Aşamaları.	38
5.2 Talep Tahminin Varsayımları.	39
5.3 Talep Tahminin Yöntemlerinin Sınıflandırılması.	40
5.3.1 Nicel Yöntemler.	41
5.3.2 Nicel Yöntemler.	42
5.4 Yapay Zeka Tabanlı Yöntemler.....	53
6. UYGULAMA VE MATERYAL.....	57
6.1 Yapay Sinir Ağı Mimarisi.	58
6.2 Yapay Sinir Ağı Matlab Uygulamaları ve Eğitilmesi.....	58
6.3 Sonuçların Test Edilmesi ve Değerlendirilmesi.	63
7. SONUÇ VE ÖNERİLER	69
KAYNAKLAR	71
EKLER	75
ÖZGEÇMİŞ	87



KISALTMALAR

ARIMA	: Durağan hale getirilmiş otoregresif hareketli ortalama
ARMA	: Otoregresif hareketli ortalama
CPI	: Tüketici fiyatları endeksi (ing.)
GA	: Genetik algoritma
GSYH	: Gayri safi yurtiçi hasıla
İMKB	: İstanbul menkul kıymetler borsası
MAE	: Ortalama mutlak hata
MAPE	: Ortalama mutlak yüzde hata
MSE	: Ortalama hata kareleri
MSPE	: Kök ortalama yüzde hata kare
PPI	: Üretici fiyatları endeksi
R	: Korelasyon katsayısı
RA	: Regresyon analizi
RBF	: Radyal tabanlı fonksiyonlar
TÜİK	: Türkiye istatistik kurumu
TÜFE	: Tüketici fiyatları endeksi
ÜFE	: Üretici fiyatları endeksi
Yt	: Gözlenen gerçek değer
YSA	: Yapay sinir ağları



ÇİZELGE LİSTESİ

	Sayfa
Çizelge 4.1. Veri Madenciliğinin Genel Kullanım Alanları	30
Çizelge 6.1. YSA'ya göre tahmin performansı	62
Çizelge 6.2. YSA sonucu bulunan tahmini değerler ile gerçek değerlerin karşılaştırılması.....	63





ŞEKİL LİSTESİ

Sayfa

Şekil 3.1: Yapay Sinir Hücresi.....	10
Şekil 3.2: Yapay Sinir Ağlarının Kara Kutu Benzetimi.....	16
Şekil 3.3: Yapay Sinir Ağları Yapısı Blok Gösterimi.....	16
Şekil 3.4: Yapay Sinir Ağları İşlem Süresi.....	17
Şekil 3.5: Yapay Sinir Ağları Mimarileri.....	20
Şekil 3.6: İleri Beslemeli Yapay Sinir Ağları.....	21
Şekil 3.7: İleri Beslemeli Çok Katmanlı Yapay Sinir Ağları.....	22
Şekil 3.8: Geri Beslemeli Geri Yayılmalı Sinir Ağ Model Mimarisi.....	23
Şekil 4.1: Veri Madenciliğinin Birçok Disiplinle Bileşimi.....	30
Şekil 4.2: Veri Madenciliğinin Bilgi Kelif Sürecinin Aşamaları.....	32
Şekil 4.3: Veri Madenciliğinin Metotları.....	33
Şekil 5.1: Box Jenkins Metodolojisi.....	47
Şekil 5.2: En Küçük Kareler Yöntemi.....	51
Şekil 6.1: Matlab Giriş Tanımlamaları.....	57
Şekil 6.2: Matlab Yeni Tanımlama Penceresi.....	58
Şekil 6.3: Yapay Sinir Ağı Gösterimi.....	58
Şekil 6.4: Matlab'ta YSA eğitim ekranı.....	59
Şekil 6.5: Eğitim, doğrulama ve test kümelerine ilişkin hata performansları.....	60
Şekil 6.6: Matlab'ta öğrenme, doğrulama ve test kümelerine ilişkin grafiği.....	61
Şekil 6.7: Matlab'ta YSA test ekranı.....	62
Şekil 6.8: YSA ile bulunan tahmini değerler ile gerçek değerlerin grafik gösterimi.....	65



YAPAY SINIR AĞI TEKNİKLERİ KULLANARAK EĞİTİM YAYINCILIĞI SEKTÖRÜNDE VERİ MADENCİLİĞİ

ÖZET

Bu tezin amacı, insan beynindeki sinir ağlarının çalışmasından yola çıkılarak oluşturulan Yapay Sinir Ağları (YSA)'nın, eğitim yayıncılığı sektöründe satış tahmininde nasıl kullanılabileceğini araştırmak ve satış tahminini yapmak için en uygun YSA modeline ilişkin bir örnek sunmaktır.

Kurumların günlük operasyonları her gün binlerce veri oluşturuyor. Yapılan her şey, atılan her adım, kurulan bir iletişim, yazılan her şey bir veri ve hepsi bir anlam içermektedir. Rekabetin arttığı günümüzde fark oluşturmak için birçok kurum tarafından ihtiyaç duyulan bilgi, karşımıza çıkan verilerin anlamlı bir şekilde düzenlenmesi ile sağlanmaktadır. Dosya ve veri tabanlarında kayıtlı çoğlan verilerle veri madenciliğinin asıl hedefi; verilere ilişkin bilgiyi keşfetmek ve karar verme sürecine yardım edebilecek veri tabanındaki yararlı bilgileri elde etmektir.

Bu çalışmada eğitim yayıncılığı sektöründe faaliyet gösteren bir firmanın verileri kullanılmıştır. İlgili firmanın bilgi siteminden veriler alınarak satış tutarını etkileyebileceği düşünülen kriterler ortaya çıkarılmıştır.

Satış talebini etkileyen faktörler; Satış Hacmi, Öğrenci sayısı, hane eğitim harcaması, dolar kuru, müşteri sayısı, Tüfe ve Üfe'dir. Yapay sinir ağının ürettiği sonuçların gerçeği ne kadar yansıttığı istatistiksel olarak araştırılmıştır. Elde edilen sonuçlar, yapay sinir ağlarının eğitim yayıncılığı ile alakalı gelecekteki satışları tahmin etmede başarıyla kullanılabileceğini ortaya koymuştur.

Ana Kelimeler: yapay sinir ağları, eğitim yayıncılığı, veri madenciliği, satış tahmini



NEURAL NETWORK TECHNICAL AND EDUCATIONAL BROADCASTING DATA MINING SECTOR

ABSTRACT

Artificial neural networks are created by working out the neural networks of the human brain. The purpose of this thesis is to investigate how artificial neural networks can be used in sales forecasting in the education publishing sector for making the most suitable model for sales forecasts.

The daily operations of the corporations create thousands of data every day. Everything that is done, every step, communicate with somebody, everything written are datas and they all have a meaning. In order to create difference In today's competitive world, the information has to be ensured with well-organized as meaningful data. The main objective of the data mining with increasin amount of data is to provide multiple copies of files and databases; discovering information about the data and obtaining useful information from the database that can help the decision-making process.

Data were obtained from the relevant company's information system and the criteria were developed with using this data which could affect the sales amount. In this study, the data was used which is a company operating in the field of education publishing sector.

The results of the artificial neural network are statistically investigated Factor affects are; sales volume, number of students, education expenditure, dollar exchange rate, number of customers, TUFÉ and UFE result shows that artificial neural network can be used to estimate the future sales of the educational publishing.

Keywords: artificial neural networks, educational publishing, data mining, sales prediction



1. GİRİŞ

Tüm Kurumlar gelecekte, şu anki var olan konumlarını korumak ve iyileştirebilmek için gelecekte yaşanabilecek olayları tahmin etmek ve iyi yapılmış planlar çerçevesinde faydalı çözümler üretmek için devamlı karar vermek zorundadırlar. Kurumların gelecekte yaşanabilecek olayları önceden öngörmek, çeşitli veri ve yöntemleri kullanarak önceden önlemler almak tahminin asıl amacıdır ve talep tahmin işleminde de bu amaç öngörülmektedir. Yapay zeka kavramı, bilgisayarda yapılan uzun zamanlı çalışmaların neticesinde bilim adamlarının insan beynini modellemesi sonucunda hayatımıza girmiştir. Yapay sinir ağları adını verdikleri yeni bir alan adı bu adımları izlenmesi sonucu ortaya çıkmıştır. Yapay sinir ağları tekniği, güvenilir sonuçlar vermesi ve doğrusal olmayan sorunların çözümünde aktif olarak kullanılması zamanla yaygınlaşmasına neden olmuştur.

Yapay Sinir ağları yönteminin hemen hemen tüm çevrelerde kullanılıyor olması, bu tahmin modellemesi için de geliştirilmiş yeni metotlardan bir tanesi olmasına rağmen, Türkiye'deki çalışmalar bu çerçevede dünya literatürüne göre çok az olduğu görülmektedir. Ülkemizde, yapay sinir ağları ile ilgili araştırmacıların artık yoğunlaşılması ve bu yöntem ile tahmin, veri kavramlaştırması, sınıflandırma ve kontrol sorunları çözümü gibi benzer birçok konuda çözümler geliştirilmesi, ülke bilimimize önemli faydalar sağlayacaktır. Ayrıca birçok yeni mimari yöntemlerin geliştirilmesi, genetik ve bulanık mantık algoritmaları yardımı ile yapay sinir ağı yönteminin çok daha iyi bir şekilde geliştirilmesi konusunda da çalışmalar yürütülmesi önemli faydalar sağlayacaktır. Böylelikle ülkemiz dünyada yeterli çalışma ile temsil edilmesi ve ülkemiz yeni teknolojiler üretmesi mümkün olabilecektir.

Yapay Sinir Ağları (YSA) günümüzde tahmin yöntemi amacı ile nerdeyse her alanda yaygın olarak kullanılmaktadır. Özellikle gelenekse yöntemlere göre doğrusal olmayan zaman serilerinde YSA önemli bir başarı göstermektedir. Bu yöntemin tercih edilmesinde, bu başarının önemli bir etkisi olmuştur (Zhang vd, 1998:35-62).

Literatürde bu konu ile ilgili çeşitli alanlarda yapılmış fazlaca sayıda çalışma bulunmaktadır. Ancak eğitim yayıncılığı sektöründe ne yazık ki durum hiç de iyi değil. Eğitim yayıncılığı sektöründe satış tahminine yönelik hiç bir çalışmaya rastlanamamıştır. Eğitim yayıncılığı sektöründe bu durumun çözümüne yönelik fayda sağlamak da bu çalışmamızın hedefleri arasında bulunmaktadır.

Dosya ve veri tabanlarında kayıtlı çoğalan verilerle veri analizi yapmak, bu verileri anlamlı hale getirmek için veri madenciliği gibi sağlam araçların geliştirilmesi önemlidir. Veri madenciliğinin asıl hedefi; verilere ilişkin bilgiyi keşfetmek ve karar verme sürecine yardım edebilecek veri tabanlarından yararlı bilgileri elde etmektir. Eğitimsel datasetlerinde veri madenciliği teknikleri bu verilerin analizine ve bu verilere ilişkin görünmez bilgilerin bulunmasına yardımcı olmak için kullanılmıştır.

Çalışmada, YSA yardımıyla eğitim yayıncılığı satış yapan bir firmanın dosya ve veri tabanındaki 2010-2014 yılları arasındaki verileri kullanarak 2015 yılının il bazlı satışların tahmin edilmeye çalışılmış ve gerçek veriler karşılaştırılmıştır. Aynı yıllara ait veriler Veri madenciliği kullanılarak, geri yayılım modeli (backpropagation network) metotları kullanılarak da tahminler yapılmış ve bu sonuçlara göre karşılaştırmalar yapılmıştır.

2. LİTERATÜR ÇALIŞMASI

Literatür çalışmamızda YSA ile ilgili, birçok alanda yapılmış yüzlerce talep tahmin çalışması bulunmaktadır. YSA ile yapılmış ilk tahmin çalışmasında hava durumu tahmin edilmiştir. Bu çalışmadan sonra Hu, 1964 yılında kurumlarda yapılan olan YSA modeli çalışması, YSA modelini ünlü hale getirmiştir. Kurumlarda YSA modeli tahmin çalışmaları, öncelikle ekonomi, finans alanlarında tamamlanmış ve faydalı sonuçlar elde edilmiştir. Zamanla kurumlarda farklı konularda da tahmin çalışmaları giderek yaygın hale gelmeye başlanmıştır. Çalışmanın konumuzla da ilgili olarak literatür taraması için uygulamalardan bazıları incelenmiş ve aşağıda özetlenmiştir.

Gevcar vb (1999) bu çalışmada, SEKA kağıt fabrikasında üretilen 8 farklı kağıt ürününün gelecek satış tahminini yapmışlardır. Bu çalışmada kağıt talebini etkileyen faktörler; GYMH, Nüfus, ithalat, ihracat, kağıt ve basım sanayisine ait toplam eşya fiyat endeksi faktörlerini dikkate almıştır. Kağıt talep tahminleri çoklu regresyon ile yapılmış ve gerekli analiz bu değişkenler arasındaki ilişki korelasyon ederek belirlenmiştir.

Yıldırım (2014), Ankara il sınırları içinde artarak meydana gelen trafik kazalarına çözüm olabilmesi için alternatif güzergâh yolları seçeneği sunan bir yapay sinir ağı modeli geliştirmeyi amaçlamaktadır. Bu model oluşturulurken Emniyet Genel Müdürlüğü'nden temin edilen 2008, 2009 ve 2010 yıllarında Ankara il sınırları içinde meydana gelen kaza tespit tutanakları temel olarak alınmış, risk analizi yapılmış ve riskli noktaları tespit etmek için yapay zekâ teknikleri uygulanmıştır. MATLAB R2013a yazılımı ve Levenberg-Marquardt öğrenme algoritmasına göre çalışan algoritma kullanılmıştır. Risk kriterleri oluşturulduktan sonra, bu algoritma kullanılarak eğitim ve test süreçlerinden geçirilmiş verilerin %95'in üzerinde bir doğrulama oranına sahip olduğu gözlenmiştir. Google Maps teknolojisinin harita gösterme, harita üzerine işaret noktası ekleme ve rota hesaplaması özelliklerinden faydalanılarak görsel olarak sürücünün daha az riskli güzergâhlara yönlendirilmesi sağlanmıştır.

Sönmez, Zontul ve Bülbül (2015), Aktif karlılığı ve öz kaynak karlılığı ile ifade edilen banka karlılığı üzerinde etkisi olan değişkenlerin kullanılmasıyla ve ilk defa geliştirilecek

adaptif bir yazılım modeli ile Türkiye'deki mevduat bankalarının karlılığını önemli bir EH tekniği olan yapay sinir ağları ile analiz etmektir. Modelden çıkan sonuçlar, kullanılan değişkenlerin tamamının karlılık üzerinde değişen oranlarda önemli etkisinin olduğunu ve tahminlerin hedeflenen ve kabul edilebilir başarı performansını yakaladığını göstermektedir. Bu başarılı sonuçlarından dolayı ve kullanıcı farklılıklarından etkilenmemesine de bağlı olarak, bu yazılım modelinin; banka karlılığı tahmininde kolaylıklar sağlayacağı düşünülmektedir.

Sönmez (2013) bu çalışmada, geliştirilecek adaptif bir esnek yazılım modeli ile Türkiye'deki mevduat bankalarının karlılığını YSA ile analiz etmektir. Banka karlılığı üzerinde etkisi olan değişkenlerin kullanılmasıyla geliştirilecek olan esnek hesaplama modelinin, farklı çalışma alanlarında ve modellerde de kullanılabilir yapıda olması hedeflenmektedir.

Eti (2016), Aktif kârlılığı dört farklı yöntem ile modellenerek karşılaştırılmaktadır. BİST'te işlem gören teknoloji şirketlerinin finansal tabloları üzerinden çoklu doğrusal regresyon, lojistik regresyon, karar ağaçları ve yapay sinir ağları modelleri kurulmuştur. Daha sonrasında bu modeller değerlendirilerek karşılaştırılmıştır.

Özçalıcı (2015), YSA üzerine araştırmalar yapılarak enerji sektöründe kullanılan tahmin modelleri incelenmiş ve Nisan 2015 - Mart 2016 arası saatlik elektrik enerji talep tahmini için ilgili değişkenler kullanılarak Türkiye net elektrik enerji talebi tahmin edilmiştir.

Kirby (1966), Singer dikiş makinesi üretimini, kısa ve orta vadeli talep tahmin yöntemlerinin karşılaştırılmasını yaptığı bu çalışmada, 5 değişik ülkeden alınmış 7,5 Yıllık dikiş makinesi satış verilerini oluşturduğu 23 değişik dizi kullanarak bir talep tahmin çalışması yapılmıştır. Bu çalışmasında, hareketli ortamlar, zaman serileri ve üstel düzleştirme analizlerinde en küçük kareler metotlarını kullanmıştır. Çalışmanın neticesinde mevsimsel durum içeren üstel düzleştirme ve trend analizi yöntemi çok iyi neticeler çıkardığı sonucuna varılmıştır. Bu çalışmasında, verilerin özellikleri, tahmin doğruluğuna ve zaman dilimine göre göre değişiklik gösterdiği görülmüştür.

Amerika'da Carlson ve Umble (1980), gelecek 5 yıllık talep tahmini belirlemek üzere, lüks ve standart otomobil kategorisine ait 5 farklı tür otomobil araştırmasında, çoklu regresyon analiz tahminleme tekniği yöntemi kullanılmıştır. Bu çalışmada benzin fiyatları, otomobil fiyatları, tüketici gelirleri, benzin azlığının piyasaya olan etkileri ve Amerika otomotiv

sanayisi çalışanlarının grevleri talebi etkileyen faktörlerin olduğu tespit etmiştir.

Akbyay vd. 1999'da yapmış olduğu çalışmasında, nitel bir talep tahmin yöntemi olan Tobit beş yöntemi ile Türkiye'deki gıda ürünlerine olan talebin tahminlenmesi çalışması yapılmıştır. Bu çalışmasının sonuçları özellikle konsantre meyve suyu üretimi yapan firmalar için önemli katkılar bulunmaktadır. Bu çalışmaya göre, satıcılar Pazar talepleri arttırmak için 12 - 17 yaş grubu tüketicilere daha çok yoğunlaşması gerektiği ve özellikle eğitim seviyesi iyi olan annelerin, ürünlere olan olumsuz bakışlarının değiştirilmeye çalışması gerektiği belirtilmiştir.

Chen (2000), Amerikan Kuzey Caroline devlet üniversitesinde, Turizm ve eğlence sektöründe olan talebi tespit etmek için bir doktora tez çalışması yapılmıştır. Çalışmada, örnek seçilen 3 Amerikan Milli parklarına giriş yapılan ziyaretçi sayıları gibi verilerle talep tahminler yapılmıştır. Çalışmasında ARIMA istatistiksel tahmin yöntemi ile diğer istatistiksel metotlar karşılaştırılmıştır. Diğer yöntemlere göre daha isabetli tahminler üretimi için ARIMA, hem yıllık hem de sezonluk verilere göre yapılmış tahmin sonuçlarında çok iyi performans gösterdiği gözlemlenmiştir.

ZhoumcMahon vd (2002), Avustralya Melbourne şehri bölgesine ait su tedarik sistemine ait 6 yıllık, günlük su tüketimi verileri ile zaman serileri analiz metodunu da kullanılmış, gelecekte olacak su ihtiyaç talep tahmini gerçekleştirmiştir.

Cahow (2004), evinde tedavi gören kronik hastaların bakımı ile görevli olan hemşire talebi, Çoklu Regresyon ile Monte Carlo simülasyon yöntemleri kullanarak tahmini gerçekleştirmiştir. Çalışmasında, emeklilik ve sağlık anketlerinde elde edilmiş verilerin yapılan tahmin sonuçlarına göre, bu talebe olan ihtiyaç Amerika'da 2025 yılına kadar hızla artacaktır.

Satır ve Köksal (2006), ARIMA modeli ile entegre tavuk üretimi yapan bir firmanın finansal planlanması için talep tahmin çalışması yapmışlardır. Çalışmada, 2 senelik geçmiş veriler kullanılmış ve 90 çeşit ürünün firma tarafından üretimi için zaman serisi 6 metotları ile talep tahmin uygulaması yapılmıştır. Çalışma modeli, sonuçlarına göre yeterli bulunularak bazı ufak değişikliklerle diğer entegre tavuk üreticilerinde de kullanarak yayımlanabileceğini ileri sürmüştür.

Griffiths vd, (2010), Avustralya'daki 5 değişik eyalet verileri kullanarak, yerel buğday verimliliği tahmin çalışmasını Regresyon Modeli ile bazı belirsizlikleri önemsemek için tahmin çalışması yapılmıştır. Tarım sezonu süresince yağın

yağmurlar, buğdayların yetişmesinin en önemli belirleyicisi olduğundan, bu çalışma için geçmiş sezonlara ait yağış verilerini toplanmış ve Regresyon modeli kullanılarak tahmin çalışması yapılmıştır.

Sun vd, (2010) turizm sektöründe son zamanlardaki pazar payı süratle büyüyen gemi turu endüstrisi, Müşteri potansiyeli için talep tahmin çalışmasını yapmışlardır. Bazı belirsizliklere rağmen uygulamanın sonuçları, oldukça tutarlı ve güvenilir olduğunu gösterilmiştir.

Wong vd. (1997), 1988-1995 yılları arasında yayınlanmış yapay sinir ağları uygulamaları ile alakalı bilimsel çalışmaları bir anket yardımıyla kontrol ettiği çalışmada; yapay sinir ağı uygulamaları her geçen süre yükselen bir hızla işletme faaliyetlerinde kullanıldığını görülmüştür. Bu çalışmada, yapay sinir ağları var olan veya gelişen yeni teknolojilere çok çabuk uyum sağladığı belirtilmiştir. Ayrıca bilgisayar temelli sistemler de ve yapay zekâ teknolojilerde yapılmış yeniliklerin, yapay sinir ağları teknolojisinin kurum araştırmaların da kullanımı için çok yeni imkanlar sunduğu belirtilmiştir.

Kirby vd. 1997 de otoyoldaki araç trafik yoğunluk tahmini, Gürbüz 2008 de yük ve yolcu taşımacılık konusunda talep tahmini, Yaşar 2009 da otobüs yolcusu talep tahmini, Tsai vd. 2009 da demiryolu taşımacılığındaki yolcu talebi gibi konularda yapılan tahmin çalışmalarında, Yapay sinir ağları yöntemi kullanılmıştır. Bazı geleneksel yöntemler kullanılarak çalışmada, sinir ağı yöntemi karşılaştırma yapılarak yapay sinir ağı yönteminin trafik, yolcu vb ulaşım sorunlarında tahmin performansında geliştirme gösterdiği ve doğru sonuçların elde edildiği belirtilmiştir.

Chung (2001), şehir kanalizasyonun kirlilik yoğunluğunu belirlemesi, Yüksek (2007), hava kirlilik tahmin çalışması, Shuai ve Gong (2009), çevrenin kirlenme yükselişinin tahmini gibi şehirlerde olabilecek ilerde meydana gelecek çevre felaketlerine karşı ve altyapı planlamasındaki felaketleri önceden belirlemek ve tedbirler alınmasında fayda sağlayacak çalışmalarla gelecek verilerin üretilmesi amacı ile ysa yöntemini kullanılarak tahminleme çalışmalarını yapılmıştır.

Çuhadar vd. (2009) ve Hu (2002), iç ve dış turizmin talep tahmin çalışmalarını, yapay sinir ağları yöntemlerini diğer geleneksel yöntemlere göre daha iyi tahminde bulunduğu, geliştirilen model verilerle arasında bir doğru ile ilgili olmayan ilişkilerin öğrenilerek genellenen yapılabildiğini ve böylece bundan önce hiç karşılaşılmamış

problemlere bile önemsenmeyecek seviyedeki hata sınırlamaları içerisinde çözüldüğünü belirtmişlerdir.

Yu (2003) Tahminleme için, e-ticaret yapan işletmeler veya tedarik zinciri yönetimi için agent tabanlı model önerilmiştir. Çalışmasında, önerilen modeli aslında temelinde ysa modelini oluşturmuş olup, temin sürelerinin ve talep miktarlarının net olup olmadığı, tedarik zinciri yönetim süresince, yeterli seviyede güvenilir sonuçların üretildiği belirtilmiştir.

Yu (2008) ve Kaynar (2010), çalışmalarında, Yapay Sinir ağları ile ham petrol fiyatlarının tahminindeki karmaşık ilişkileri başarıyla modellemeyi başarmışlardır. Çalışma sonuçları yapay sinir ağı yönteminin en iyi performansı gösterdiğini ispatlamıştır.

Jones (2008), doktora çalışmasında, hastanelerdeki ilk yardım bölümlerindeki talep tahmin ihtiyacını modellemek ve değerlendirmek için geri beslemeli, gizli katmanlı bir ysa modeli tasarlamıştır. Bu modelde, giriş katmanı için tatil dönemlerindeki haftalık, aylık talep veri bilgileri değişkenleri ile oluşturulmuştur. Geliştirilmiş bu modeldeki işlemci parçaların ağırlıkları ve geri yayılım algoritması sayesinde güvenilir tahmin sonuçları alınmıştır.

2009 yılında Aksoy ve Dahamsheh'lerin yaptıkları çalışmada, Ürdün yağın yağış miktarı tahminini, yapay sinir ağları ile geliştirdikleri bir yöntem kullandılar. Çalışmada, Ürdün bölgesindeki yağmur yağışları, bölgede en önemli su kaynağı olması sebebi ile, bu yüzden yağışlar bu bölgedekiler için hayati derecede önemlidir.

Avcı (2009), IMKB-30 endeksinin içinden seçilmiş bazı hisse senetleri günlük kazançlarını, yapay sinir ağı modeli ile tahminlemesini yapmıştır. Çalışmada, yapay sinir ağları yönteminin, hisse senedi getirilerinin tahmininde etkili ve faydalı olduğu gözlenmiştir.

Asilkan (2009), ikinci el otomobil piyasanın gelecekte olabilecek fiyatları tahmin etmek için yapay sinir ağlarını kullanmıştır. Çalışmasında, ysa uygulaması ile elde ettikleri sonuçlar, zaman serisi analizleri ile elde ettikleri sonuçlar ile karşılaştırılma yapılmış ve sonuçlar, yapay sinir ağlarının ikinci el otomobil piyasasında gelecekteki fiyatları tahminden daha başarılı sonuçlar çıkardığını göstermiştir.

Birçok konuda yurtiçi ve yurtdışında yapılan literatür incelemelerinin sonuçlarında talep tahmini ve yapay Sinir ağı ile ilgili çalışmalara rastlanmıştır. Bu çalışma literatüre katkı sağlamak amacı ile genelde Türkiye'nin, özelde firmalara fayda sağlamak ve gelir kaynağı olması için eğitim yayıncılığı sektörünün, il bazlı satış tahminiyle ilgili olarak çalışma yapılmıştır. Firmalar açısından satışı etkileyen birçok faktör bulunmaktadır. Bu sektörle alakalı yapılan çalışmalar ışığında il bazlı satış tahmininde önemli zorluklarla karşılaştığı görülmektedir. Bu çalışma eğitim yayıncılığı sektöründeki kolaylık sağlamak ve literatüre katkıda bulunmak için yapılmıştır.



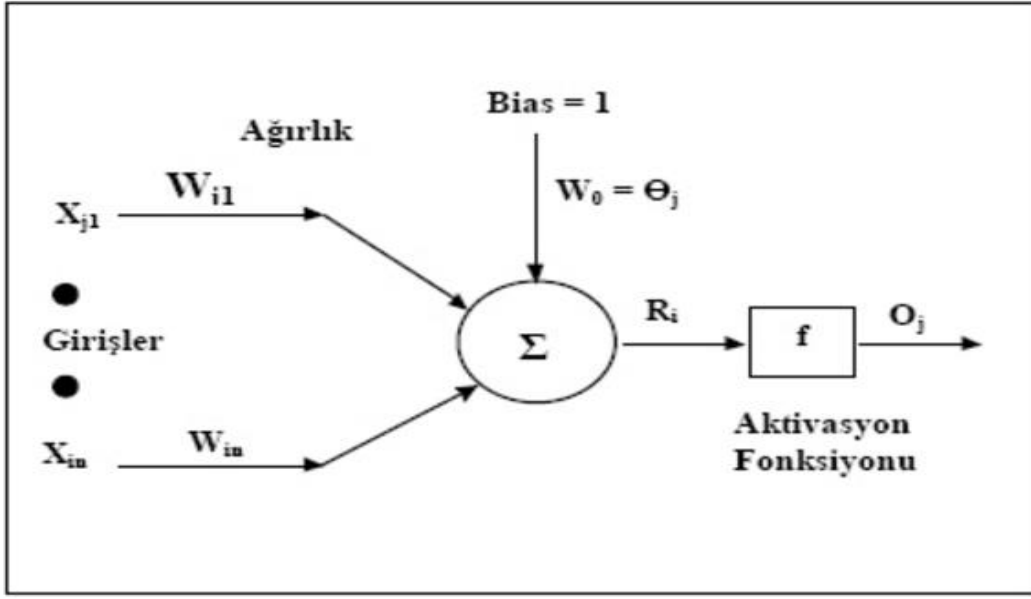
3. YAPAY SİNİR AĞLARI

3.1 Yapay Sinir Ağları Nedir?

İnsan beyninin çalışma şekliyle esinlenerek geliştirilmiş olan Yapay sinir ağları (Artificial Neural Networks - ANN), birbiri ile paralel çalışmakta olan, birbirine bilgiyi ileten ve bilgiyi alan bir yapıdan oluşmaktadır. Bir ağ şeklinde birbirine bağlanan Yapay sinir hücreleri problem çözmek amacıyla kullanılır. Hücreler arasındaki bilgi akışını sağlayan bağlantıların değerleri, ilişkilerle gösterilmekte ve Sistemin öğrenme yeteneğini ve zeki davranışını, bağlantı değerleri kullanılması ile sağlanmaktadır (Tekin, 2009: 229).

Yapay sinir ağları, İnsan beyninin bir çok özelliği bulunmaktadır. Bunlardan bir tanesinde, öğrenme yolu ile yeni bilgilerin oluşturabilme, yeni bilgilerin keşfedebilmesi ve yeni bilgiler türetebilme gibi yeteneklerin rastgele bir yardıma ihtiyaç olmadan otomatik bir şekilde gerçekleştirilmesi amacı ile geliştirilen bilgisayar sistemleridir. (Öztemel, 2006: 29). Yapay sinir ağları modelinin sembolik gösterimi aşağıda Şekil 3.1’de verilmiştir.

Yapay sinir hücresi, yapay sinir ağlarının çalışmasına esas teşkil eden en küçük birimlerdir. Yapay Sinir ücretleri, ağırlıklar, girdiler, aktivasyon fonksiyonu, birleştirme fonksiyonu ve çıkış olmak üzere Şekil 3.1 de görüleceği üzere 5 ana bileşeninden oluşmaktadır.



Şekil 3.1 Yapay Sinir Hücresi (Öztemel, 2006: 29)

Yapay sinir ağları bir programcıya gerek kalmadan, kendi kendine öğrenme özelliğine sahip sistemlerdir. Bu ağlar öğrenme gibi yeteneklerinin yanında, bilgiler ve ezberleme arasında ilişki kurma yeteneğine de sahiptirler. Birçok Yapay sinir ağları bulunması ile birlikte bunların bazılarının kullanımı diğerlerine göre daha fazladır. Bu yapay sinir ağlarından bir tanesi olan **geriye yayımlı yapay sinir ağı** olarak bilinmektedir. Bu tip ağlar özellikle sınıflandırma ve tahmin işlemlerinde başarılı sonuçlar verdiği görülmektedir.

Nöronların birbirleri ile ağırlıklar aracılığıyla çeşitli şekillerle bağlanmasıyla Yapay sinir ağı oluşmaktadır. Ayrıca Yapay sinir ağları, bu nöron bağlantılarının oluşturduğu katmanlar şeklinde sıralanmaktadır. Yapay sinir ağları, insan beyninin öğrenme sürecinde olduğu gibi ve ona uygun bir şekil de bir öğrenme algoritması eşliği ile kendisine sunulan veriyi derler ve bu verilerden bir çıkarım yapar. Bu çıkarımı ile öğrenmiş olduklarını, nöronlar arasındaki ağırlıklar aracılığı ile saklar ve bu öğrenileni, tüm veri uzayı için genelleme kabiliyetine hakim bir işlemci olarak da gösterilebilmektedir.

Özellikle sınıflandırma, tahmin uygulamaları ve modelleme olmak üzere yapay sinir ağları pek çok alanda kullanılmaktadır. Yapılan bu uygulamaları incelendiğimizde, Yapay sinir ağları, kusurlu, kesin olmayan, çok boyutlu, karmaşık, eksik, gürültülü, , hata yapma olasılığı yüksek sensör verileri bulunduğu problemi çözmek için matematiksel modelin ve algoritmalarının bulunmadığı durumlarda yaygın olarak kullanıldığı görülmektedir.

3.2 Yapay Sinir Ağları Genel Özellikleri

YSA'lar, birçok alanda başarı ile kullanılan ve çözümler sunan, genelleme, tahmin etme, doğrusal olmama, öğrenme, adaptasyon, hata toleransı, donanım ve yazılım olarak gerçekleştirilebilme gibi birçok özellikleri vardır. Bu özellikler aşağıda kısaca açıklanmıştır.

- Yapay sinir ağları kullanıma alınmadan önce eğitilmesi ve test edilmesi gerekmektedir. Mevcut örnekleri incelediğimizde test kümesi ve eğitim olmak üzere iki bölüme ayrılmaktadır. Eğitim işinin tamamlanmış olarak kabul edilebilmesi için ayrılan bölümlerdeki eğitim kümesi ile ağ eğitilir ve ağın bütün örnekler için doğru cevaplar sunmaya başlamış olmasıdır. Bu zamana kadar hiç görülmemiş test kümesi verileri, YSA tarafından kabul edilebilir bir seviyede doğru cevaplar sunuyorsa YSA'nın performansı iyi kabul edilmektedir ve kullanıma alınır.
- Daha önce hiç görülmemiş örneklerin hakkında bilgi üretebilir ve algılamasına yönelik olayları kullanabilirler.
- Görüntüleri ilişkilendirebilir ve sınıflandırma yapabilirler. Eksik kalan görüntülerin kalan parçalarını tamamlayabilir.
- Hata toleransına sahip ve eksik bilgiyle çalışabilmektedirler.
- Bir hata meydana geldiğinde ağ, büyük bir hata ile birden bire bozulmaz. Dereceli bir bozulma gösterirler.
- Bilgi tüm ağa yayılmış durumda ve dağıtık belleğe sahiptirler.
- Sembolik ifadeler ile sayısal değer karışıkları olması gerekmektedir sadece nümerik bilgi ile çalışmaktadırlar (Öztemel 2006).
- Algılanmaya yönelik olaylar kullanılabilir; Sınıflandırma ve şekil ilişkilendirmesi yapılabilir ve örüntü tamamlaması gerçekleştirebilir.

YSA, önemli avantajların yanında bazı dezavantajları da bulunmaktadır. Örneğin YSA'lar oluştuktan sonra bir bilgi içermediği için herhangi bir problem için direkt kullanılamaz. Yapay sinir ağları bu nedenden dolayı öncelikle problemin giriş ve çıkışlarına göre eğitilmelidir. Çok kolay olsa bile başlangıç koşullarından bağımsız olarak problem çözemezler. Çünkü karar verirken sadece önceden öğrendiği

koşullara göre çözüm üretirler. Eğitimde kullanılan örnekler ağı daha sonraki problemleri çözmesinde etkili olmasından dolayı eğitim verisi kaliteli olmalı, yanlış veya eksik bilgi içermemesi ve tüm veri uzayını kapsamaması gerekir. YSA'nın giriş ve çıkış arasındaki ilişkiyi bulma veya öğrenme şekli, ağırlıkların değiştirilmesi ile olduğundan YSA'nın problemi nasıl çözdüğü bilinmemektedir. Bu da YSA'nın dezavantajlarından biridir.

3.3 Yapay Sinir Ağları'nın Kısa Tarihçesi

İlk YSA, nörolog Warren McCulloch ve bir bilim adamı olan Walter Pitts tarafından 1943'de, elektrik devreleri kullanımı ile insan beyninin hesaplama yeteneğinden esinlenerek basit bir ysa modeli başlanmıştır.

Hebb, 1949 yılında öğrenme ile ilgili temel teoriyi "Davranış Organizasyonu" adlı kitabında, konu edinmiştir. Hebb tarafından geliştirilen kural Hebbian öğrenme kuralı olarak adlandırılmaktadır. Geliştirilen bu kural, yapay sinir ağının bağlantı sayısı değiştirildiğinde öğrenmenin olabileceğini öngörmektedir (Öztemel, 2006: 29)

Farley ve Clark, 1954 yılında Rassel ağlar ile Adaptif tepki üretme terimlerini ortaya koymuştur. 1958 yılında bu kavram Rosenblatt ve 1961'de ise Camiello tarafından geliştirilmiştir (Kargı, V. 2015).

Özellikle 1958 yılında Rosenblatt tarafından geliştirilen "Perceptron" yapay sinir ağlarındaki çalışmalar hızlandırmıştır. Perceptron (algılayıcı), örüntü (şekil) tanıma amacıyla geliştirilen eğitilebilen, tek katmanlı ve tek çıkışa hakim olan bir yapay sinir ağıdır. Perceptron'un daha sonra geliştirilecek ve yapay sinir ağları çalışmalarında devrim kabul edilen çok katmanlı sinir ağlarının temelini oluşturması açısından tarihsel önemi de vardır (Yücesoy, M. Temizlik.2011).

ADALINE (Adaptive Linear Neuron) modeli, Widrow ve Hoff tarafından 1959 yılında ortaya çıkarılmıştır. Böylelikle Yapay Sinir Ağı'nın mühendislik uygulamalarında kullanılmasına başlanmasında atılan ilk adımlardan birini oluşturmaktadır. 1970'lerin sonlarında ise ADALINE modelinin çok katmanlı hali olan MADALINE'nin temelini oluşturmaktadır (Öztemel, 2006: 29).

MADALINE modeli ise, telefon hatlarındaki oluşan yankıları ortadan kaldıran bir uyarlanabilir süzgeç olarak adlandırılmaktadır (Kargı, V. 2015).

Minsky ve Papert 1960'lı yılların sonunda iki matematikçi, yazdıkları "Perceptrons" isimli kitaplarında algılayıcıların doğrusal olmayan problemlere çözüm üretemediklerini ortaya koymuşlardır. YSA'nın XOR problemini çözemediğini kanıtlamalarıyla birlikte bu alanda yapılan çalışmalarda bir duraklama yaşanmıştır. Bu nedenle birçok kişinin YSA'ya olan güveni sarsılmış ve yatırımlar yarıda bırakılmıştır. Amerika Birleşik Devletleri'nde araştırma ve geliştirme çalışmalarını yürüten DARPA, YSA ile ilgili olan tüm çalışmalarını desteklemeyi durdurmuştur (Öztemel, 2006: 29).

Hopfield, 1982 yılında özellikle geleneksel bilgisayar programlama ile zor olan XOR problemlerini, çok katmanlı algılayıcılar ile çözmüştür. Bu çalışmaların pratikte uygulanabilir olması YSA'ya olan ilgiyi yeniden arttırmıştır. Hopfield, tekli algılayıcılar ile çözülmeyen XOR problemlerini çok katmanlı algılayıcılar ile çözerek YSA'nın işe yaradığını söyleyen bütün tezlerin çürütülmesine yol açmıştır.

1986 yılında Rumelhart ve arkadaşları tarafından YSA'da yaygın olarak kullanılan geriye yayılma algoritması geliştirilmiştir. Birden çok katmanlı ağların, tek katmanlı ağların çözemeyeceği XOR problemini geriye yayılım algoritması ile çözmüştür.

Radyal tabanlı fonksiyonlar (RBF) modeli 1988'de Broomhead ve Lowe tarafından geliştirilmiştir. Bu ağın çok katmanlı algılayıcılara alternatif bir ağ olduğunu belirtmişler ve bu ağlar, özellikle filtreleme ve veri sıkıştırma problemlerinde kullanılmaktadır.

Spetch 1990'da, Olasılıksal Sinir Ağlarını (Probabilistic Neural Network) geliştirmiştir. Olasılıksal sinir ağları, radyal tabanlı fonksiyonların daha gelişmiş şeklidir. Spetch 1991'de bu çalışmalarından sonra Genelleştirilmiş Regresyon Ağlarını (RNN) geliştirdi.

Sonraları YSA'ları pek çok fen ve mühendislik alanında uygulanmıştır. Bugünlerde ise basit desen tanıma problemlerinden, çok karışık DNA algılama ve sınıflandırma problemlerine kadar genişlemiştir. YSA uygulamaları finans, fizik bilimi, ekonomi ve sosyal bilimlere kadar bir çok alanda uygulama alanı bulmaktadır.

3.4. Yapay Sinir Ağlarının Avantajları

YSA, özellikleri ve yapısı sayesinde birçok önemli avantajları vardır. Geleneksel yöntemlerle, gerçek dünyada açıkça görülemeyen ilişkileri çözmek mümkün

olmayabilir. Bu gibi durumlarda ise YSA ile çözüme ulaşılabilmektedir. YSA örneklerden öğrenebilme ve eksik bilgi ile çalışabilme özelliği ile örnekler yardımıyla kendi kendine öğrenir. YSA'nın avantajları aşağıdaki gibidir:

1. Yapay sinir ağları, problemi çözerken diğer geleneksel hesaplama yöntemlerine göre zamanı daha verimli kullanır.
2. Yapay sinir ağları, örnekler yardımıyla öğrenir ve kendisini geliştirir. Sadece giriş verilerinin sağlanmasıyla veya giriş verilenin karşılığı olarak çıkış verileri, YSA'nın bir problemi öğrenmesi için gerekmektedir. Ayrıca YSA'nın yapısına göre uygun düzenlenmiş olmalı ve öğrenme kümesi için yeterli sayıda örnek içermesi gerekmektedir.
3. Yapay sinir ağları doğrusal olmayan yapıya sahip oldukları için, gerçek hayattaki problemlere daha optimal çözebilmektedir.
4. Yapay sinir ağları değişen bir ortamda da esnekliğe sahiptir.
5. YSA Şekil tanıma, genelleme, sınıflandırma ve ilişkilendirme konularında güçlü bir yöntemdir. YSA, eğitim sürecinden hemen sonra çıkış verilerini, eğitim kümesinin dışındaki veriler için üretir. Test verileri ile bu çıkışlar test edilir. Eğer bu çıkış değerleri kabul edilebilir hata değeri içerisinde ise, YSA genelleme yapabilmektedir.
6. Yapay Sinir Ağlarının yeniden eğitebilir olması için yeni bilgilerin ortaya çıkması ve sistemde bazı değişikliklerin olması gerekmektedir (Gürsoy, A.2012).
7. YSA, eksik bilgi ile çalışabilmektedir ve ayrıca belirsiz olan bilgileri işleyebilme özelliğine sahiptir.
8. YSA'nın hata toleransına sahip olması nedeniyle, ağıın herhangi bir hücresinin bozulması ağıın tümünü etkilememektedir. Fakat ağıın bozuk olan hücresinin etkisine göre, ağıın performansında azalma olabilmektedir.
9. YSA'lar paralel çalışabildikleri için, günlük yaşamda gerçek zamanlı olarak kullanımları daha kolaydır.

3.5. Yapay Sinir Ağlarının Dezavantajları

YSA'nın yukarıda belirtilen avantajlarına karşılık aşağıdaki dezavantajları da vardır:

1. YSA'da ağı yapısının oluşturulması, modelin seçilmesinde belli bir kural yoktur. Genellikle deneme yanılma yöntemiyle kişilerin tecrübesine ve sezgilerine bağlı olarak yapılmaktadır ve bu şekilde yapılması önemli bir sorun teşkil etmektedir. Çünkü sorun için uygun bir ağ oluşturulamazsa problemin çözümünden istenen sonuç alınamayabilir ve ağa duyulacak güven azalır.
2. YSA, Doğru çözüme her zaman ulaşamayabilirsiniz.
3. Diğer bir önemli sorun ise, YSA'lar paralel çalışabilme özelliği yüzünden bir donanım bağımlı olarak çalışırlar.
4. Ağı eğitime ne zaman son verileceği ile ilgili kesin belirli bir yöntem yoktur.
5. Bazı Yapay sinir ağlarında, ağı parametre değerlerinin nasıl belirleneceği ile ilgili bir kural yoktur.
6. Kullanılacak öğrenme algoritmasının YSA yapısına uygun belirlenemeyebilir.
7. Yapay sinir ağı davranışları açıklanamaz.

3.6 Yapay Sinir Ağlarının Yapısı

Yapay sinir ağları bir diğer ifade ile kara kutu olarak tanımlanabilir. Çünkü, Çıktıların üretimi için bir hiyerarşik yapıya göre birbirine bağlanmış ve birden çok basit işlemci elemanın girişi ile yapılan verilerden çıktılar üretilebilir. Bu kara kutunun görevi, matematiksel olarak fonksiyonu temsil etmektir. Yapay sinir ağlarında bu fonksiyonun tam olarak bir matematiksel karşılığı bulunmamaktadır. Diğer bir ifadeyle, modelin matematiksel denklemlere değil de örneklere ihtiyacı görülmektedir. Öğrenmenin gerçekleştirilmesi için modelin sadece eski veriler ile ilgili örnek verilere ihtiyaç bulunmaktadır. Öğrenmeyi gerçekleştirme, geçmişe ait örnek veri girişleri ile sonuçlar üretebilen kara kutu benzetimi aşağıda Şekil 3.2'de verilmiştir.

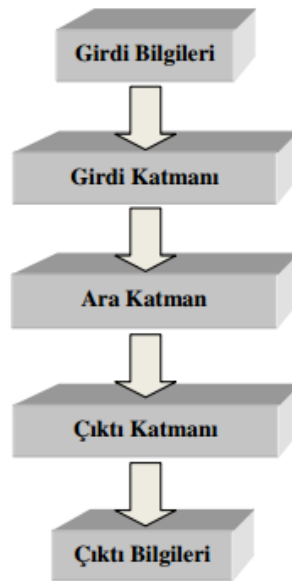


Şekil 3.2: Yapay Sinir Ağlarının Kara Kutu Benzetimi (Karahana, 2011:72)

Kara Kutuya benzetilen yukarıdaki şekilde (3.2’de) görüldüğü gibi sinir ağların, tüm hücrelerden bilgi toplama ve bu toplama bilgilerin işlenerek diğer elemanlara gönderilme özelliğinde sahiptir. Bu anlamda farklı algoritmalar ve yaklaşımlar söz konusudur.

Yapay sinir ağları, öğrenmeyi gerçekleştirmek için geçmişteki gerçek örnek verilerden tecrübe kazandıklarından, diğer uzman sistemlerinde olduğu gibi veri toplam problemi yoktur. Ancak kullanılmakta olan örneklerin, bilgisayarın öğrenmesi için gerekli ilişkilerin doğru bir şekilde temsil etmesi gerekmektedir. Ağın sahip olduğu topolojik yapı, Problemin ağa sunum şekli, ağın kullanıldığı öğrenme stratejisini ve öğrenme kurallarını, ağın performans üzerindedeki etkili olacaktır. Yapay Sinir ağını oluşturan işlemci elemanlar birbirleriyle devamlı irtibat içindedirler (Toktaş ve Aktürk, 2004: 7).

Yapay sinir ağlarının işleyişi aşağıda Şekil 3.2’de görüldüğü üzere bir toplu şema üzerinde gösterilmiştir.



Şekil 3.3: Yapay Sinir Ağları Yapısı Blok Gösterimi (Toktaş, 2004: 7)

Yukarıda Şekil 3.3’de gösterildiği üzere, yapay sinir ağları, girdi katmanı, ara katman

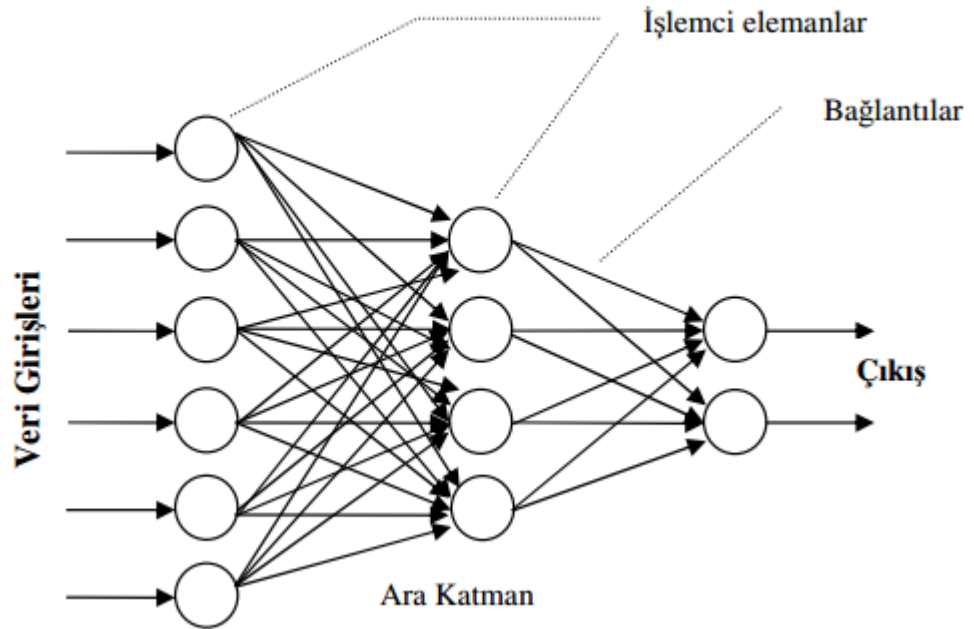
ve çıktı katmanından olmak üzere 3 katmandan meydana gelmektedir. Bu katmanların aşağıda gibi açıklanmaktadır (Adıyaman, 2007:8).

Girdi Katmanı: En az bir girdi elemanın bulunduğu katman Girdi katmanıdır. Girdi katmanındaki veriler rastgele bir işleme doğru olup olmadığına bakılmadan giriş ile aynı değerde çıktı değeri üretmektedirler.

Ara Katmanlar: Girdi değerlerinin belli muamelelere tabi tutulduğu kısımdır. Seçilen ağ yapısına göre işlem katmanı, fonksiyonu ve yapısı da değişebilir. Ayrıca ara katman, bir katmandan oluşabileceği gibi birden fazla katmandan da oluşabilmektedir.

Çıktı Katmanı: Çıktı katmanı, en az bir çıktıdan oluşmaktadır. Çıktı ağ yapısında bulunan fonksiyona bağlıdır. Bu katmanda işlemler gerçekleştirilir. Burada üretilen çıktılar aynı zamanda dış dünyada iletilmektedir.

Şekil 3.4’de, yapay sinir ağları işlem süreci aşağıda gösterilmektedir. Görüldüğü üzere sistemin, geçmiş döneme ait veri girişleri yapılmasından sonra işlemci nöronlar ve bağlantı elemanları işlem süresine çıkışa doğru devam ettirmektedir.



Şekil 3.4: Yapay Sinir Ağları İşlem Süreci (Yüksek, 2007: 15).

Yapay sinir ağları hücresi, temel bir anlamda biyolojik sinir hücresine göre çok daha

sade bir yapısı vardır. Yapay sinir ağları hücresinde, temel anlamda dış ortamdakiden veya diğer nöronlardan alınan veriler, toplama fonksiyonu, ağırlıklar, aktivasyon fonksiyonu, girişler ve çıkışlar vardır. Dış ortamlardan alınan veri ağırlıkları aracılığı ile nöronlara bağlanmaktadır. Bu ağırlıklar ilgili girişin etkisini belirlemekte ve toplam fonksiyonunu ise net girişini hesaplamaktadır. Net girişler ise, bu girişlerle ilgili ağırlıklar çarpımı bir sonucudur. Aktivasyon fonksiyonunda işlem sürecince net çıkışı hesaplamasını yapar ve bu işlem hem de nöron çıkışı bilgisini vermektedir. Genel anlamda ise aktivasyon fonksiyonun da doğrusal olmayan bir fonksiyonudur (Yüksek, 2007: 15).

YSA birden çok yapay sinir hücresinin bir araya gelmesi ile oluşmaktadır. Bu yüzden bir yapay sinir hücresinin anlaşılması tüm ağın anlaşılmasına yardımcı olacaktır.

Yapay sinir ağları, en temel anlamda 5 bileşenden oluşur. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve çıkış olarak 5 bileşen şeklinde sıralanmaktadır. Bu 5 bileşenlerle ilgili kısa açıklamalar aşağıdaki gibi verilmiştir.

1. Girdiler; Dış dünyadan yapay sinir hücresine gelen bilgilere denilmektedir. Bu bilgiler, diğer hücrelerden veya normal yoldan da, dış dünyadan geldiği gibi gelebilir (Öztemel, 2006: 49). Girişlerin amacı verileri bir ilerki aşamaya iletmekten farklı hiçbir amacı bulunmamaktadır. Girişler, diğer bir ifade ile belirtmek istersek, veri üzerinden hiçbir matematiksel işlem yapmadan sadece bir ileten görevi vardır. Yapay sinir ağlarının dış dünya ile olan ilişki halinde olan iki elemandan birisi giriş katmanıdır. Bir nöronun çevreyi algılaması ile bağlı olarak sınırsız sayıda giriş olabilir, ancak tüm nöronlar sadece tek bir çıkışı olmalıdır. Yapay sinir ağlarının algılayıcılarına girdiler denilebilir. (Çelik, 2008: 30).

2. Ağırlıklar; YSA sistemine giriş yapılan veriler ve bu bağlantıların üzerindeki ağırlıkların vasıtası ile hücreye girmeyi sağlar ve buldukları giriş hücresinde böylelikle etkiler. Matematiksel katsayısı olması, ağırlıkların nöronda girdi olarak kullanılacak değerlerin bir başka özelliğidir. Nöronlar ile Girdiler arasındaki iletişimi sağlayan bütün bağlantıların, farklı ağırlık değerleri olması ve bu ağırlıkları tüm işlem elemanlarının üzerinde etkili olmasına neden olmaktadır. Hücreye gelen bilgiler, Ağırlıkların, hücre üzerindeki etki ve önemini göstermektedir. Ayrıca ysa, öğrenme işlevini, ağırlıkların değiştirilmesinin sayesinde başarmaktadırlar. Ağırlıklar, biyolojik sinir hücresindeki aksonlar olarak da düşünülebilmektedir (Adıyaman, 2007; Çelik, 2008; Gürbüz, 2008). Ayrıca ağırlıkların başlangıç

değerlerinin genelde (-1 ile +1), aralığında rastgele gelmektedir.

3. Toplama Fonksiyonu; Biyolojik nöronda bulunan dendritlerin yapmış olduğu görevleri yapan toplama fonksiyonu, aslında birleştirme fonksiyonunun en yaygın kullanılan türüdür ve bir hücreye gelen net girdilerin hesaplandığı bir fonksiyondur. Genellikle girişlerin ilgili ağırlıklarla çarpımı, toplamı şeklinde de ifade edilir. Hücreye gelen net girdi bu fonksiyon ile hesaplanır. Toplama fonksiyonunun değişik fonksiyonlarda olmakla birlikte, en çok kullanılan ağırlıklı toplama fonksiyonu olmaktadır (Öztemel, 2006; Gürbüz, 2008).

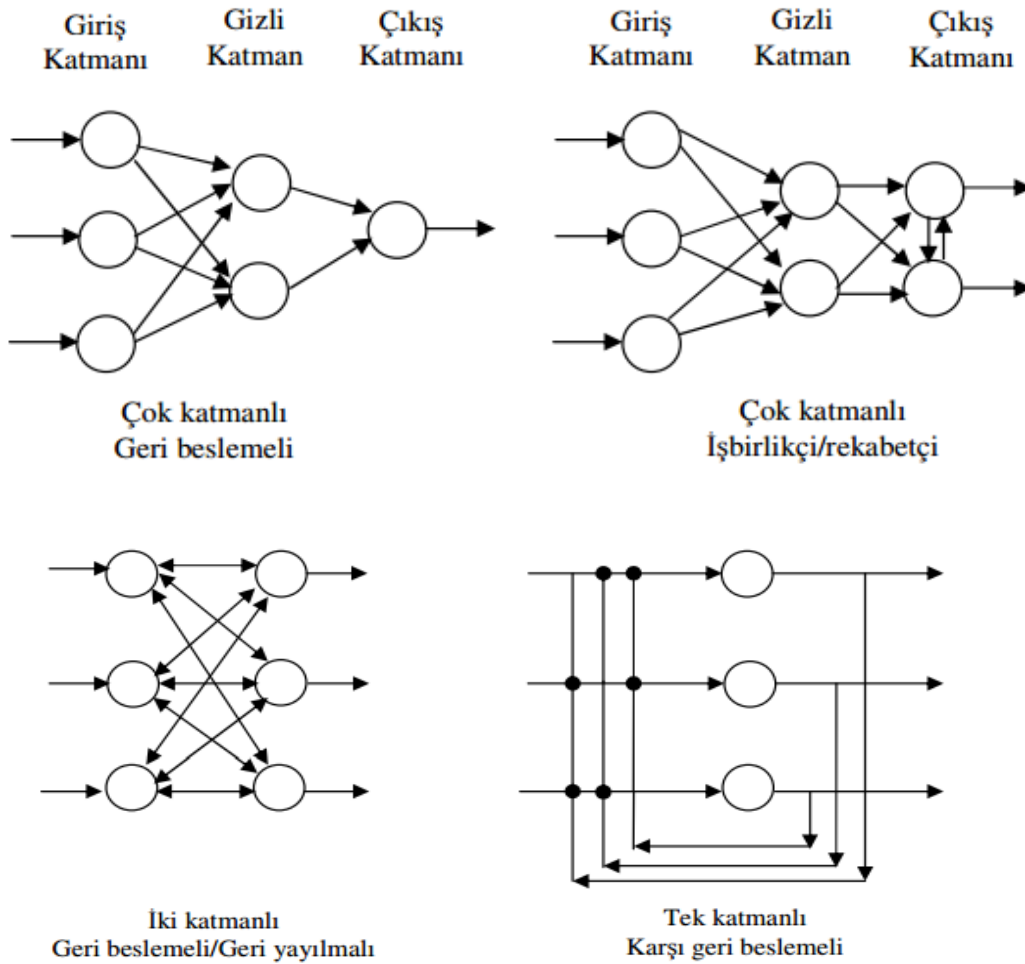
4. Aktivasyon Fonksiyonu; Aktivasyon fonksiyonu, üreteceği çıktıyı belirlemek için, hücreye gelmiş net girdiyi işler ve hücrenin bu gelen girdi için karşı olarak üreteceği çıktıyı belirler. Aktivasyon fonksiyonu, Toplama fonksiyonundaki gibi de çıktıyı hesaplayabilmek için farklı formüller kullanılmaktadır. Bu fonksiyon türünün alınabilir bir fonksiyon olması, bazı modellerde şart koşulmaktadır. Aktivasyon fonksiyonu, tüm ağdaki işlemci elemanlar, aynı fonksiyonun kullanılması gerekmez. Bazıları aynı fonksiyonu, diğer elemanlar ise farklı fonksiyonları kullanmalarında sakınca yoktur. Sorun olması durumunda en uygun fonksiyon, tasarımcının yaptığı denemelerin sonucunda kendisi belirleyebilir. Bir fonksiyonun genellikle, doğrusal olması tercih edilmeyendir. Aktivasyon fonksiyonu olarak hangi fonksiyonunun seçileceği, sinir ağı verileri ve ne öğrenmek istediğine bağlı olarak değişmektedir. Doğrusal, sigmoid ve tanjant hiperbolik türleri, en çok kullanılan fonksiyonlardır. Çıktı değerlerinin belirli sınırlar içerisinde kalması, Aktivasyon fonksiyonları ile sağlanmaktadır. Toplama fonksiyonunun da olduğu gibi aktivasyon fonksiyonu, işlemci elemanlardan farklı fonksiyonlarda kullanmaları mümkündür. Sigmoid fonksiyonu, en çok katmanlı Algılayıcı modellerinde kullanılmaktadır (Öztemel, 2006; Adıyaman, 2007; Gürbüz, 2008).

5. Hücre Çıktısı; Aktivasyon fonksiyonu tarafından belirlenmiş çıktı değeridir. Üretilen bu çıktı, başka bir hücreye veya dış dünyaya gönderilir. Hücre, kendi çıktısını aynı zamanda kendisine girdi olarak da gönderebilmektedir. Çıktı değeri, aktivasyon fonksiyonu geçildikten sonra elde edilen sonuç değerine denilmektedir. Çıkış işlevi; aktivasyon fonksiyonundan alınan, $Y = f(v_i)$ çıktısını, ağın nihai çıktısı olarak dış dünyaya veya çıktıyı oluşturan nörona bağlı olan diğer nöronlara girdi olarak gönderilmesinden sorumludur. Yapay sinir ağları, tek bir nörondan oluştuğu için; bu ağ, Y çıktısını dış dünyaya nihai çıktı olarak göndermektedir (Öztemel,

2006; Adyaman, 2007; Çelik, 2008; Gürbüz, 2008).

3.7 Yapay Sinir Ağlarının Sınıflandırılması (YSA Mimarileri)

Yapay sinir ağları, sinir hücrelerini birbirleri ile farklı şekil ve biçimlerle bağlanması ile oluşmaktadır. Hücre çıkışları, ağırlıklar üzerinden kendisine giriş veya diğer hücrelere olarak bağlanabilir. Bağlantılarda gecikme birimi de kullanılabilir. Hücre bağlantı şekil durumuna göre aktivasyon fonksiyonları ve öğrenme kurallarına aktivasyon fonksiyonlarına göre farklı modeller yapılmıştır. İçinde birçok nöron bulunduran ysa, belirli topolojilerle (mimarilerle) tanımlama yapabilirler. Bu mimarilerden en yaygın kullanılan, aşağıda Şekil 3.5’de görülmektedir.



Şekil 3.5: Yapay Sinir Ağları Mimarileri (Kartalopoulos, 1996: 49)

Yukarıda Şekil 3.5’de görüldüğü gibi, Yapay sinir ağları tek ve çok tabakalı olmak şeklinde ikiye bölünebilir. Genel anlamda bir modelin beklenen çıkış bilgisini elde


etmek için yapılan bir giriş tabakasını, çıkışlar kısmının elde edilen bir çıkışı tabakası, giriş ve çıkış tabakalar arasında bulunan en az bir gizli katman bulunmaktadır. Gizli katmanın sayısı en az bir veya daha fazla olması gerekmektedir. Çünkü bir çıktı ve gizli katman olmadan direk elde edilmez (Kartalopoulos, 1996: 49).

YSA yapısına göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) şeklinde iki değişik yapıda incelenmektedir.

3.7.1 İleri beslemeli yapay sinir ağları

İleri beslemeli (feedforward) ağlarda, işlemci elemanlarında genellikle katmanlara göre ayırım yapılmıştır. İşaretler ise girdi katmanlarından çıktı katmanına tek yönlü bağlantı yolu ile iletilir. İşlemci elemanlarında, bir katman dan bir diğer katmana bağlantı kurmaya çalışırken, aynı katman içinde bağlantıları bulunamaz. Çok katmanlı algılayıcılar (MLP) ve sayısallaştırılmış öğrenme vektörü (LVQ) ağları, İleri beslemeli ağlara örnek olarak verebiliriz (Saygılı, 2008: 45).

Blok diyagram, İleri beslemeli yapay sinir ağı işleyişi aşağıdaki Şekil 3.6'de belirtilmiştir.




Şekil 3.6: İleri Beslemeli Yapay Sinir Ağları (Saygılı, 2008: 45)

Blok olarak yukarıda Şekil 3.6'de belirtilen ve yaygın bir şekilde kullanım alanına sahip çok katmanlı algılayıcı sinir ağı (MLP); bir giriş, bir ya da birden fazla gizli katmanı ve bir çıkış katmanlarından oluşmaktadır. Her katmanda, bir ya da birden fazla işlemci eleman sahip olunabilir. Aşağıdaki denklemde gösterildiği gibi, çok katmanlı algılayıcı sinir ağından çıkan herhangi bir nöron çıkışı formülize edilebilmiştir.

$$y_k = f\left(\sum_k w_k x\right)$$

İleri beslemeli sinir ağı, giriş katmanındaki veriler üzerinden rastgele bir işleme tabi tutulmadan bir ileriki katmana gönderilmektedir. Gizli katmanda, işlemcinin eleman sayısını tamamen uygulanmış sorunların giriş sayısına bağlı şekilde sistem veya tasarımcı tarafından belirlenebilir. Gizli katmanda, ara katman sayısı ve ara katmanlarda olabilecek işlemci eleman sayısı, deneme yanılma yoluyla da bulunabilir.

Aşağıdaki Şekil 3.7’de, bir gizli katmanı, birçok girişi bulunan ve iki ara katmanı bulunan, ileri beslemeli çok katmanlı ağ 2 adet çıkışa sahip bir y modeli gösterilmektedir.



Şekil 3.7: İleri Beslemeli Çok Katmanlı Yapay Sinir Ağları [1]

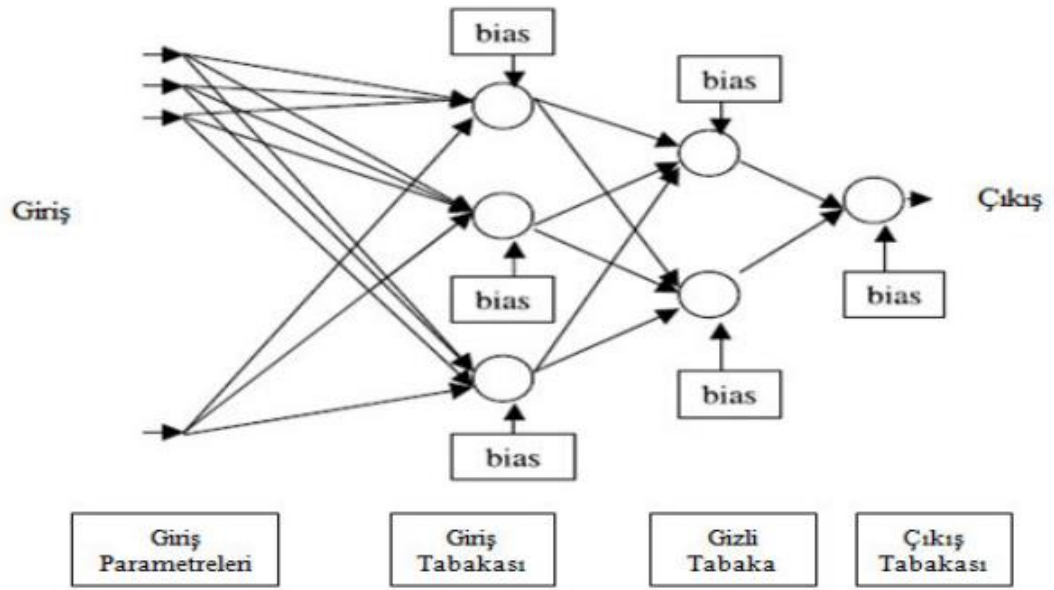
Yukarıda Şekil 3.7’de, giriş katmanında veri girişleri, ileri beslemelide bilgi işlemlerin ve çok katmanlı yapay sinir ağının gizli katmanları ve çıkış katmanlarında ise işlenmiş verilerin çıkışının alındığı alanlar, kısımlar halinde şekilde gösterilmektedir.

3.7.2 Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli geri yayımlı ağlar (Back Propagation Networks, Feed Forward),

yapay sinir ağlarının çok popüler bir modelidir. Çok katmanlı geri beslemeli ağlarda, işlemci elemanları katmanlar halinde inşa edilmiştir. İletişim halindeki elemanlar, yalnızca bitişik katmanlardadır. Bilgi yayılımı, bu tip ağlarda geriye doğru olmaktadır. Bir geri besleme düğüm noktasında yoktur. Hatalar, ağın öğrenme süresi boyunca geriye doğru yayılarak öğrenilir ve çözüme kavuşturulmaktadır (Rao ve Srinivas, 2003: 94).

Geri yayımlı sinir ağı modeli hatalarının geriye doğru yayarak öğrenmesi, yani hatalardan deneyim kazanarak uzmanlaşması, geri beslemeli süreci aşağıda Şekil 3.8'de gösterilmektedir.



Şekil 3.8: Geri Beslemeli Geri Yayılımlı Sinir Ağı Modeli Mimarisi (Rajpal vd. 2006: 810)

Yukarıda Şekil 3.8'de görüldüğü üzere, geri besleme yardımıyla model, karşısına çıkılan her hatadan bir şeyler öğrenerek ve bir sonraki adımda bu hataları tanıyarak, kolay şekilde çözümler üretilebilir.

3.8 Uygulamada Kullanılan Yöntemler

3.8.1 Geriye yayılım algoritması

Geriye yayılım algoritması, ilk defa Werbos tarafından tertip edilmiş, sonra McClland, Rummelhart ve Parker tarafından geliştirilmiş. Öğretme algoritması, anlaşılabilir ve matematiksel olarak ispatı mümkün olduğundan dolayı çok tercih

edilmektedir. Bu algoritmada olan hatalar, geriye doğru çıkıştan girişe azalarak çalışması nedeni ile geriye yayılım ismi verilmiştir. Geriye yayılımın öğrenme kuralı, ağ çıkışında olan mevcut hataların, her bir tabakadaki ağırlıkları tekrar hesaplamaktadır (Karaatlı 2012).

Geriye yayılım algoritması 7 adımla özetlenebilir,

- 1- Ağ ağırlıkları ilk değerinin hazırlanması,
- 2- Başlangıç eğitiminin vektörün ağa uygulanması,
- 3- Çıkışa sahip olmak için ağı kullanılması,
- 4- Bir hata sinyali oluşturmak için gerçek çıkışla ağın çıkışlarını kullanılması,
- 5- Ağa hata sinyalinin uygulanması,
- 6- Ağ ağırlıkları toplam hatayı düşürecek şekilde, eğitim düğüm algoritması ile değiştirilmesi,
- 7- Kabul edilebilir bir hata oranı için uygun dereceye inene kadar ağa giriş vektörünü uygulamaya devam edilmesi, (Khare 2007).

Geriye yayılım algoritması kullanılan bir ağ, ileri beslemeli algoritmasının kullanıldığı bir ağda gerekenden daha az yapay sinir hücresi kullanılmışsa verilerden dolayı daha az hassas çıkış verisi elde edilebilir ama çokça yapay sinir hücresi kullanılmış ise yeni tip verilerin işlemesi zor olacaktır. İleri beslemeli ile geriye yayımlı bir ağda aradaki katmanları atlayarak bir ileriki ağa geçilemez. Giriş katmanı, veri ilk defa uygulanmasından sonra, çıkış katmanına kadar bir çok değişik işlemlere tabi tutulmaktadır. Bu işlemler bitiminde, oluşan çıktı ile gerçek olması istenen çıktı veri arasında olan fark, her bir düğüm için bir hata belirtisi olarak hesaplanmaktadır. Toplamda olan hata, her düğüm hatasının belli bir oranı bulunduracak şekilde ara katmandaki düğümlere doğru aktarılır. Böylelikle giriş katmanı kadar düğümler, hatanın belli bir oranı sahip olur. Elde edilmiş oranlara göre bağlantı ağırlıkları tekrar düzenlenmektedir.

İleri beslemedeki ilk giriş katmanındaki veriler doğrudan gizli katmana aktarılır. Gizli katman, kendi giriş değeri ağırlıklandırılmış bir ileriki katmana veya birçok katman bulunmuyor ise doğrudan çıkış katmanına aktarmaktadır. Katmanların arasında ağırlıklar ilk başta çok ufak değerler şeklinde seçilmektedir (Başaran 2007).

İleri beslemeli ağlarda, öğrenme algoritma performansı fonksiyonu minimize etmek için performansın fonksiyon gradyeni kullanılır. Geriye yayılım algoritmasında en basit geriye yayılım algoritması olan eğim düşüm (gradient descent) algoritması kullanılır (Yurdakul 2009). Çıkış değeri hesaplanarak çıkış katmanında mevcut hata minimize edilmektedir. Hata kabul edilebilir seviyeye geldiğinde ise ağ denemeye alınabilir (Başaran 2007).

Standart geriye yayılım algoritması, çok sayıdaki sorunlar için yavaş kalmaktadır. Bundan dolayı başka bir seçenek olarak daha hızlı algoritmalar geliştirildi. Bu algoritmalar, standart sayısal optimizasyon ve deneme yanılma yöntemleri kullanan algoritmaları şeklinde iki gruba ayrılmaktadırlar. Deneme yanılma yöntemi kullanan algoritmalar, momentum terimli, öğrenme hızı değişen ve esnek algoritmalar. Standart sayısal optimizasyon tekniğini kullanan algoritmalar ise Newton, eşlenik gradyen, Levenberg–Marquardt (LM) ve Gauss-Newton öğrenme algoritmalarıdır (Doğan 2010).

Birçok ileri beslemeli ağda ve bu çalışmada, performans fonksiyonu olarak MSE kullanılmıştır. Şekil 3.1 de MSE formül görülmektedir.

$$MSE(t) = \frac{1}{N} \sum_{j \in C} \frac{1}{2} \sum_{s=1}^N (e_j^s(t))^2 \quad (3.1)$$

Burada e_j hata işareti, ağın çıkış katmanındaki yapay sinir hücrelerinin tümü ise C 'dir. $o_j^s(t)$ t. ve s. örnek olarak ağın j çıkış kısmına ait tahmin değeri, y_j^s s. örneğe ait j çıkış gerçek değeri olmak üzere t anda s örnek için ağın j çıkışına ait tahmin hatası aşağıdaki şekil 3.2 de olduğu gibi ifade edilir.

$$e_j^s(t) = o_j^s(t) - y_j^s \quad (3.2)$$

3.8.1.1 Momentum ve Öğrenme Katsayısı

Geriye yayılım algoritmasında momentum katsayısı (m) ve öğrenme katsayısı (n) kullanılır. Bu katsayılar matematiksel olarak aşağıdaki şekilde olduğu gibi ifade edilmeye çalışılmıştır.

i ve j katmanı yapay sinir hücreleri ile algoritma arasında olan ağırlıklar $w_{ij}(t)$ Δw_{ij} değişim formülü 3.3' den hesaplanmaktadır.

$$\Delta w_{ij}(t) = n x_i + m \Delta w_{ij}(t-1) \quad (3.3)$$

x_i j yapay sinir hücresine ait faktörler; Eşitlikte olan n öğrenme katsayısı, (m) momentum katsayısı, çıkış katmanındaki veya j δ ara rastgele bir j hücresine aittir.

Eğer yapay sinir hücresindeki çıkış katmanın ait ise bu faktördeki eşitlik 3.4'te olduğu gibi verilir.

$$\delta_j = \frac{\partial E}{\partial net_j} (o_j^t - y_j^t) \quad (3.4)$$

Eşitlik 3.4'te net $j = \sum w_{ji} x$ ara katmanlarda olan yapay sinir hücreleri için, 3.5'teki bu faktör eşitlik gibi verilmektedir

$$\delta_j = \left(\frac{\partial E}{\partial net_j} \right) \sum w_{qi} \delta_q \quad (3.5)$$

Herhangi bir hedef çıkış olmadığından dolayı ara katmanlardaki eşitlik 3.4'deki yerine eşitlik 3.5'teki gibi kullanılır. j δ 22 faktörü, bu duruma bağlı olması nedeni ile çıkış katmanından başlayarak bütün katmanlarda olan hücreler için hesaplanmaktadır. Bütün bağlantılardaki ağırlıklar Formül 3.1 sayesinde hesaplanıp güncellenmiş olmaktadır.

n , m değerlerinin uygun değerler seçilmesi, başarılı bir eğitim için fazlaca önem arz etmektedir. Problemlere göre bu değerlerin değişmesi mümkündür. Ayrıca bu değerler, karmaşık olan problemlerin ufak seçilmesi gerekiyor (Sarioğlu ve diğ. 2003).

Öğrenme katsayısı ağ performansında önemli etkisi bulunmaktadır. Ağırlıkların değişim oranını n bağlantı belirler ve 0-1 arasındaki değeri alır. Ağın yavaş öğrenmesi, n değerinin küçük seçilmesine, kararsızlık durumunun da değerinin büyük seçilmesine neden olmaktadır.

3.8.1.2 Levenberg-marquardt algoritması

Öğrenme algoritmaları, kendilerinden önce ortaya çıkan algoritmaların, iyi yönlerini geliştirmeye çalışarak kötü yönlerini azaltıp önceki algoritmalara alternatif olmaya çalışmaktadır.

Newton yöntemleri, eşlenik eğim düşüm algoritmasına alternatif olarak sunulmuştur. Temel amacı, Hessian matrisini performansın fonksiyon ağırlıklarında ikinci dereceden türevlerden oluşan (H) (3.6) elde etmektir (Karaatlı 2012).

$$\mathbf{H}(t) = \frac{\partial^2 E(t)}{\partial \mathbf{w}^2(t-1)} \quad (3.6)$$

Levenberg Marquardt (LM) algoritması, ağırlıkları hesaplanması, hessian matrisi ile hesaplandığında Hessian matrisi yavaş olması nedeniyle yaklaşık değeri 3.7 de bulunabilir:

$$\mathbf{n} = \mathbf{J}^T(t)(t) + \mu \mathbf{I} \quad (3.7)$$

I: Birim matris

μ : Marquardt parametresi.

J: Jakobian Matrisi

Ağ hatalarının ağırlıklarına göre birinci türevlerinden oluşan J, bir matristir ve 3.8 deki gibi hesaplanabilir:

$$\mathbf{J}(t) = \mathbf{J}(t)(t-1) \quad (3.8)$$

Bu durumdaki gradyen vektörü 3.9 ile bulunabilir.

$$\mathbf{g}(t) = \mathbf{J}^T(t)(t) \quad (3.9)$$

Ağda bulunan sinir hücreleri aralarındaki yeni bağlantıların ağırlıkları aşağıdaki formülle hesaplanabilir:

$$\mathbf{w}(t+1) = \mathbf{w}(t) - [\mathbf{J}^T(t)(t) + \mu \mathbf{I}]^{-1} \mathbf{J}^T(t)E(t) \quad (3.10)$$



4. VERİ MADENCİLİĞİ

4.1 Veri Madenciliği Nedir?

Günümüzde bilişim ve iletişim teknolojilerindeki gelişmelere paralel olarak donanım cihazlarının ucuzlaması, verilerin uzun süre depolanmaya ihtiyaç duyulması gibi vb sebeplerle de büyük kapasiteli veri tabanlarına neden olmuştur. Böylelikle büyük veri tabanlarında amaçlanan anlamlı, kullanılabilen ve ilginç bilgiye erişmek yeni bir disiplinin oluşmasına sebep olmuştur. Bu veriler, farklı istatistiksel yöntemlerle incelenip, analize tabi tutularak işletmelerin karar verme sürecine etki etmesini ve yeni stratejiler geliştirmesine katkı sağlamaktır.

Veri madenciliği, diğer bir ifade ile veri tabanındaki bilgiyi keşfedilmesidir. Büyük veri hacimlerinin arasında saklanan, anlamlı olduğu önceden tespit edilmeyen ve potansiyel olarak da yararlı ve anlaşılır bilgilerin ortaya çıkarıldığı, bununla birlikte arka planda veri tabanı yönetimi, istatistik, makine öğrenme, paralel, yapay zekâ ve dağıtık işlemlerin bulunduğu veri analiz tekniklerine, veri madenciliği adı verilir.

Veri madenciliği olarak kullanılan diğer isimler:Veri Tabanlarındaki Bilginin Keşfi (Knowledge Discovery in Database), Bilgi çıkarımı (Knowledge Extraction) , Veri ve Örüntü Analizi (Data / Pattern Anaysis) , Veri Arkeolojisi (Data Archeology), Veri Eşeleme (Data Dredging).

4.2 Kısaca Veri Madenciliğinin Tarihçesi

1950’li yıllarda veri madenciliği teknikleri ile alakalı çalışmalar yapan matematikçiler, mantık ve bilgisayar bilimleri alanlarında çalışmaların sonunda yapay zekâ “artificial intel ligence” ve makina öğrenme “ machine learning” tekniklerini keşfetmişlerdir.

İstatistikçiler, 1960’lı yıllarda regresyon analizi, en büyük olasılırlık kestirim, sınır

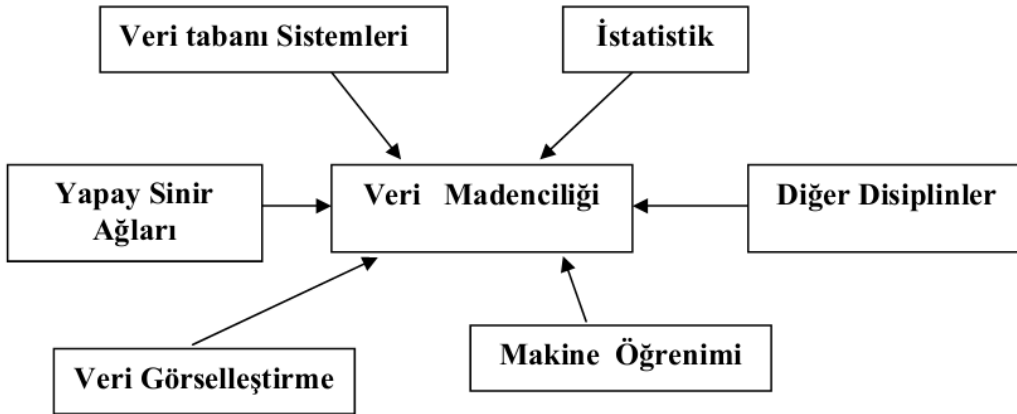
ağları vb. yöntemler veri madenciliğinin ilk adımlarını oluşturan algoritmalar keşfetmişlerdir. Ayrıca veri tabanı sistemlerinin gelişmesi ile çok sayıda veri dokümanlarının saklanması ve bilgilerin tekrar geri kazanılması sağlanmıştır.

1970, 1980, 1990'lı yıllarda yeni bilgisayar tekniklerinin ve yeni programlama dilleri geliştirilmesi, genetic algoritma, EM algoritması, K-Means kümeleme algoritması ve karar ağacı öğrenme algoritması gibi algoritmaları da içermektedir.

1990 yılı ile birlikte veri tabanlarındaki bilgi keşfinin ilk adımları böylelikle oluşturulmuştur. Büyük veri tabanlarının için veri ambarı, veri tabanı “database warehouses) geliştirilmiştir. Ayrıca aynı dönem içerisinde yeni teknolojilerle beraber, veri madenciliğinde değiştirilerek yaygın olarak kullanılmaya başlayan standart bir işin parçası olmuştur.

4.3 Veri Madenciliği Sisteminin Sınıflandırılması ve Uygulama Alanları

Veri madenciliği Şekil 4.1’de görüldüğü gibi çok düzen içeren bir alandır. Bu düzenler kümesi; veri tabanı teknolojileri, istatistik, makina öğrenme , görselleşme ve diğer düzenlerdir. Çizelge 4.1’de veri madenciliği genel kullanım alanların belirtilmiştir.



Şekil 4.1 Veri Madenciliğinin Birçok Disiplinle Bileşimi [2]

Çizelge 4.1 Veri Madenciliğın Genel Kullanım Alanları (Kaya ve Köymen, 2008)

Uygulama Alanları	Uygulama	Açıklama
Perakencilik	Benzerlik Konumu Çapraz Satış	Etkin ürünlerin benzerlikleri tespit etmek Müşteriler için birçok ürün bulunması, ürün satışları arasındaki ilişkiyi tespit etmek.
Banka	Müşteri İlişki Yönetimi	Müşteri değerlerinin tanımlanması, Müşteriler arası benzerliklerin tespit etmek, gelirleri maksimum edici programlar geliştirmek
Kredi Kartı Hareketleri	Müşteri Kaybı Analizi	Aldıkları hizmet iptal etmek riski olan müşterileri gösteren raporlar oluşturma
Siğorta, Bankacılık, Telekomünikasyon	Sahtekarlık saptama ve yöntemi	Geçmiş veri kullanılarak sahtekarlık yapanlar için bir model oluşturma ve benzeri davranış gösteren belirleme
Hedef Pazar Bulma	Pazar Analizi	Benzer özellikleri gösteren müşterilerin bulunması: Benzer gelir grupları, ilgi alanları, harcama alışkanlıkları. Benzer müşterileri otomatik olarak gruplayarak Pazar dilimlerini tanımlayın ve bu dilimleri pazarlama ve kapmanlarını hazırlarken tren analizi için kullanın.
Finans Planlaması ve bilanço değerlendirmesi	Risk Analizi	Nakit Para akışının incelenmesi ve kestirimi talep incelemesi ve kestirimi, zaman serilerinin incelemesi,

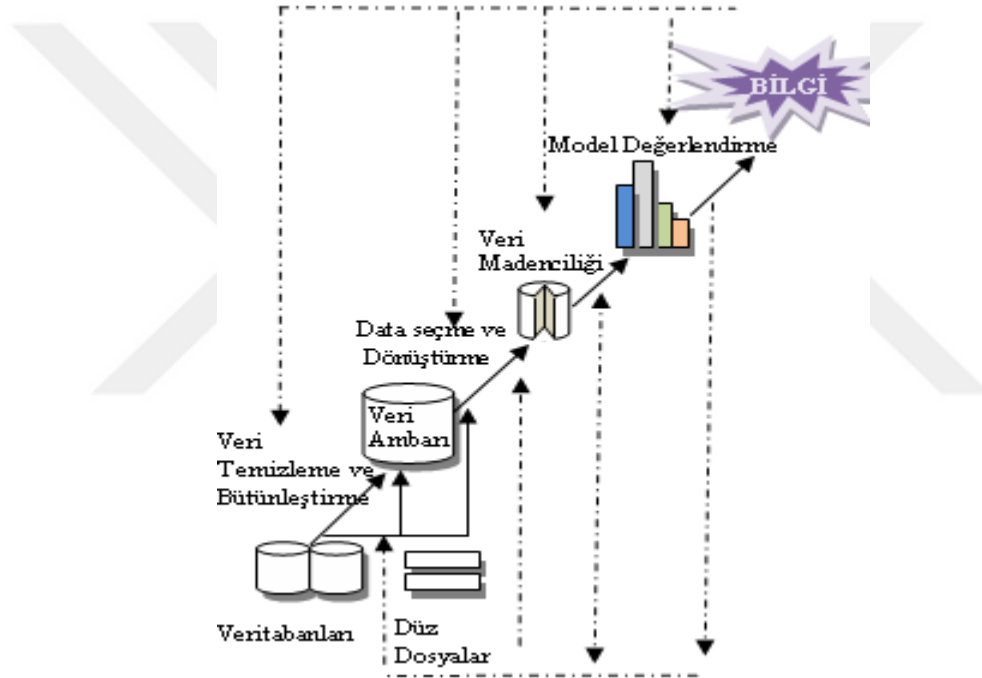
4.4 Veri Madenciliğında Bilgi Keşif Sürecinin Aşamaları

Büyük veri tabanlarında ilginç ve faydalı olan bilgiyi tespit etmek ve erişmek oldukça zordur. Veri tabanındaki bilgi keşfi ve sürecinin aşamaları (Knowledge Discovery in Databases) faydalı, önceden bilinmeyen ve kullanılabilir olan bilgiye belirli yöntemler kullanarak tanımlamada büyük rol oynamaktadır.

- 1.Uygulama alanının incelenmesi ; Konu ile ilgili uygulama ve bilgi amaçlarının belirlenmesi,
- 2.Amaca uygun veri kümesi oluşturma; Analiz edilecek verinin hangi veri tabanında yapılacağı belirtilerek, veriyi seçmek veya keşif edilecek alt veri örneklerini oluşturma,
- 3.Verinin ayıklama ve ön işleme; gereksiz ve tutarsız verilerin silinmesi,

4. Veri dönüşümü ve veri azaltma; Analizde gerekli özellikleri (boyutları) seçme, özellikler arasındaki ilişkiyi belirleme ve veri dönüşümü ya da veri birleşimi yaparak boyutları azaltma,
5. Veri madenciliği tekniğini seçme ; Sınıflandırma (classify), bağlantı kuralları (association rules), kü-meleme (clustering),
6. Veri madenciliği algoritması seçme,
7. Model değerlendirme ve bilgi sunma,
8. Bulunan bilginin yorumlanması,

Şekil 4.2’de veri madenciliği bilgi keşif sürecinin aşamaları gösterilmiştir.



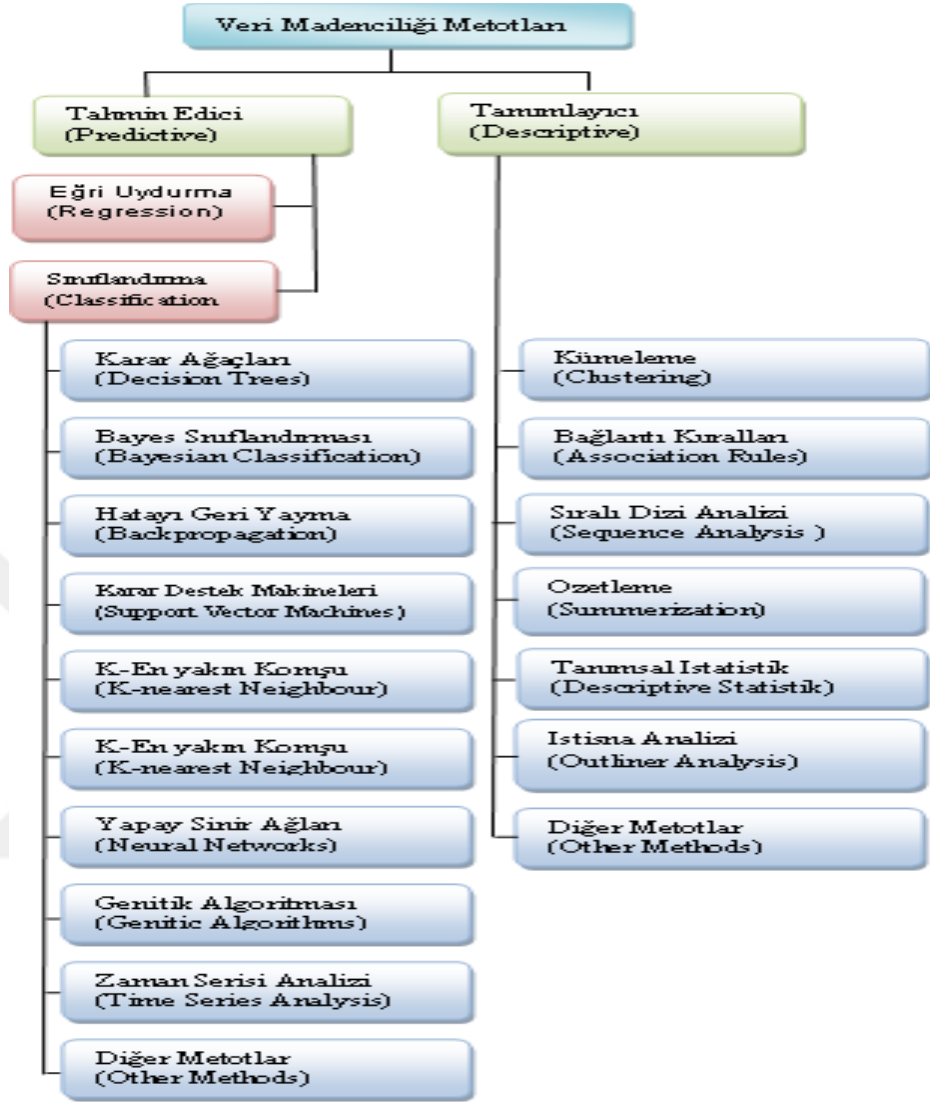
Şekil 4.2 Veri Madenciliği Bilgi Keşif Sürecinin Aşamaları (Kaya ve Köymen, 2008)

4.5 Veri Madenciliği Modelleri

Veri madenciliğinde kullanılan modeller, tahmin ve tanımlayıcı olarak iki ana başlık altında incelenmektedir.

Tahmin edici modellerde, sonuçları bilinen verilerle yola çıkarak bir model geliştirilmesi ve bu kurulan modelden faydalanarak sonuçlar bilinmeyen veri kümelerinin sonuç değerleri tahmin edilmesi amaçlanmaktadır. Tanımlayıcı model ise karar vermeye rehberlik etmede kullanılacak mevcut verilerde olan örüntülerin

tanımlaması sağlanmaktadır. Veri madenciliğin metotları Şekil 4.3'de gösterilmektedir.



Şekil 4.3 Veri Madenciliği Metotları (Han ve Kamber,2001)

Sınıflandırma: veri madenciliğinde sınıflandırma en çok kullanılan alandır. Sınıflandırma kuralları, var olan veri tabanındaki bir kısım eğitimde kullanılarak oluşturulmalıdır. Bu kuralların yardımı ile yeni bir durum ortaya çıkması ile nasıl karar verileceğini belirlenir

Sınıflandırma grubu veri madenciliği içinde en sık kullanılan teknik karar ağaçlarıdır. Ayrıca lojistik regresyon, sinir ağları, diskriminant analiz ve fuzzy setleri de kullanılmaktadır. İnsanlar veriler daima sınıflandırmaları, kategori ettikleri ve dereceleri için sınıflandırmanın, hem veri madenciliği temeli olarak hem de veri hazırlama aracı olarak da kullanılabilir.

Kümeleme: kümeleme işlemi, veriler kendi aralarında olan benzerlikleri göz önüne alarak gruplandırılmasına denir. Kümeleme yöntemleri genellikle veri arasında uzaklıkları kullanır. En yakın olan komşu algoritması ve en uzak komşu algoritması, Hiyerarşik Kümeleme yöntemleridir. Hiyerarşik olmayan kümeleme yöntemlerinin arasında ise k-ortalamlar metodu kullanılır.

Uygulamadaki bulunan birçok kümeleme metodu kullanılmıştır. Bu yöntemlerin, değişkenlerin arasında benzerliklerde veya farklılıklarda yararlanarak bir kümeyi alt kümelerine ayırmakta kullanılmıştır.

Küme, birbiri ile yakın nesnelere çok boyutlu uzayda oluşturduklarından bulutlar benzetmesi' şeklinde tanımlama yapılabilir. Bu kümeleri oluşturma işlemi kümeleme analizidir.

Londra'da 1854 yılında kolera salgını baş göstermiş. Çok ciddi ölümlerle sonuçlanmıştır (10.675 kişi). Harita üzerinde John Snow, ölen kişilerin yerleri işaretleyip bakıldığında kayıpların bazı bölgelerin üzerinde yoğun olduğu fark ediliyor. O bölgedeki su pompaları incelendiğinde atık su tesisinde bulunan sorun tespit edilerek koleradan kaynaklanan ölümler engellenmiştir. Ana sokakların birindeki su pompası sapının çıkarmak kolera salgınının sonlanmasına yeterli olmuştur (Jacquez GM, Grimson R, Waller LA.1996; 17:385-97). Kâğıt kalemle yapılan ilk analiz, yukarıdaki veri madenciliğinde kümeleme yönteminin analizidir. Veri miktarı az olmasına rağmen kağıt kalemle yapılmakta bir problem yok ama günümüzde bu pek mümkün olmuyor.

Birliktelik Kuralları: Veri tabanı içinde var olan kayıtların birbiri ile olan ilişkilerini inceleyerek, hangi olayların eş zamanlı olarak birlikte gerçekleşebilecekleri ortaya koymaya çalışan veri madenciliği yöntemlerine denir. Özellikle pazarlama alanlarındaki uygulamalarda kullanılmaktadır. Birlikte olma kuralları, bu yöntemlerin belirli olasılıklarla ortaya koyar.

Birliktelik çözümlerine örnek olarak kullanılan en yaygın uygulama, perakende satışlarda müşterilerinin satın alma eğilimleri belirlemek amacı ile yapılmaktadır. Müşterilerin bir anda satın aldığı tüm ürünleri ele alarak yapılan uygulamalara "Pazar sepet çözümleri" denilmektedir.

Örneğin; Müşterilerin bir mağazadan aldığı ürün %60'ının aynı alışverişte aynı ürünü satın aldıklarını söylemek, birliktelik çözümlerine gerçekleşen olaylara örnek olarak verilebilir.

Birliktelik kurallarının üretilmesi için kullanımı için en yaygın yöntem apriori algoritmasıdır.





5.TALEP TAHMİNİ VE TAHMİN YÖNTEMLERİ

Bu bölümde talep tahmininin tanımı, aşamaları, nasıl yapıldığı, talep tahmin yöntemleri anlatılmıştır.

Talep, tüketicilerin bir ürün veya hizmeti belirli bir fiyat seviyesinden almaya hazır oldukları miktardır. Talebi etkileyen faktörler arasında; ürün ve hizmetin fiyatı, tüketicilerin gelir seviyeleri, tüketici alışkanlıkları, ihtiyacın şiddeti, mevsimsel etkenler sayılabilir. Tahmin, en basit anlamı ile geçmişe bakarak gelecek hakkında karar verme anlamına gelmektedir.

Talep tahmini, bir firmanın ürün satışlarının gelecek sezonlar için ne olacağını belirlemek ve önceden bilmek için, geçmiş dönem verilerinin düzenlemek ve analiz edilmesi sürecine denilmektedir. Bu ürünlerden ne kadar satılacağı, tüketicilerin taleplerinin hangi ürünler üzerinde olacağı ve bu taleplerin hangi tarihlerde gerçekleşeceğini talep tahminleri ile öğrenmek mümkün olabilmektedir.

Talep tahmininde üç tür yöntem kullanılmaktadır. Bu yöntemler kantitatif, kalitatif ve yapay zeka tabanlı yöntemler olarak adlandırılmaktadırlar. Son dönemlerde teknolojinin gelişmesiyle yapay zekâ tabanlı yöntemlerde kullanılmaya başlanmıştır. Kalitatif yöntemler daha çok kişisel çıkarımlara ve deneyimlere dayanırken, kantitatif yöntemler ise istatistiksel ve matematiksel yöntemlere dayanmaktadır. Klasik yöntemlerle çözülemeyen veya istenilen performans alınmadığı durumlarda, daha karmaşık veri yapılarını çözümlenebilen yapay zekâ tabanlı yöntemler de çoğunlukla kullanılmaktadır.

Nitel tahmin yöntemi, çalışılan konular üzerinde uzman bir kişinin görüş ve deneyimlerini dikkate almaktadır. Aynı veriler üzerinde farklı kişiler farklı tahminlerde bulunabilir. Bu yöntemin kullanılma nedeni, uygulamasının kolay olması ve çok fazla zaman almamasıdır. Ayrıca çoğunlukla ucuz maliyet ve ileri derecede istatistiksel işlemlere ihtiyaç duymaması da tercih edilme nedenleri arasında sayılabilmektedir.

Nicel yöntemler matematiksel ve istatistiksel yöntemlere baz almaktadır. Bu yöntemler eğer elimizde konu ile ilgili yeterli nümerik veriler varsa kullanılabilir. Geçmişe ait bilgilerin olması, bu bilgilerin sayısal olarak ifade edilmesi ve değişkenin geçmişte gösterdiği yapının gelecek zaman içinde devam edeceği şartlarını sağlıyorsa kullanılması uygundur.

Talep tahminleri genellikle dört dönem için yapılmaktadır. Bunlar çok kısa süreli tahminler, kısa süreli tahminler, orta süreli tahminler ve uzun süreli tahminlerdir.

1. Çok kısa süreli tahminler: Genellikle günlük veya haftalık yapılan tahminlere denmektedir. Stokların kontrolü, günlük üretim programlarının hazırlanması ve sipariş vermek amacıyla yapılırlar.
2. Kısa süreli tahminler: Bir hafta ile altı ay arasında yapılan tahminlere denmektedir. Makine kapasitesi ve işgücü ayarlamaları amacıyla yapılırlar.
3. Orta süreli tahminler: Altı ay ile beş yıllık süre arasında yapılan tahminlere denmektedir. Tedarik süresi belirsiz olan satın almalarının planlanması için yapılması uygundur.
4. Uzun vadeli tahminler: Beş yıl ile daha uzun süreli olarak yapılan tahminlere denmektedir. Genellikle yeni yatırımlar yapılmadan önce bu tahminlerin yapılması daha uygundur.

Talep tahmininde göz önünde bulundurulması gereken ilkeler aşağıdaki gibidir:

1. Tahminler, miktar veya çeşit bakımı yönünden büyük olan ürün grubuna göre yapılması daha müsaittir.
2. Tahminler, kısa dönemler için daha doğruluğu daha fazladır.
3. Tahmin yöntemi kullanılmadan önce mutlaka performansının test edilmesi gerekir.
4. Tahmin kesin talebin yerini tutamaz.

5.1 Talep Tahmin Aşamaları

1. Talebi etkileyen faktörlerin belirlenmesi: Talep tahmini yapmadan önce firmanın özellikleri, talep tahminin yapılacak olan ürünün özellikleri, firmanın durumu, firmanın hedeflerinin ne olduğu, aynı ürün için rakip firmalarının piyasada olup

olmadığı, ülkenin ekonomik durumu, yaşanan veya yaşanması muhtemel teknolojik gelişimler vb. faktörlerin belirlenmesi gerekir ve bu ürünün talebi için ağırlığın ne olduğu tespit edilmelidir.

2. Verilerin toplanması: Tahmini etkileyecek olan faktörlerin belirlenmesi ve bu faktörlere ait verilerin toplanması, yapılacak olan talep tahmini çalışmasını en etkileyen en önemli aşamasıdır. Kullanılacak veriler geçmiş dönemlere ait verilere ait olabileceği gibi, bulunabilecek daha önceden oluşan istatistiksel ya da ülke ekonomisine ait iktisadi veriler de olabilmektedir.

3. Talep tahmin döneminin tespiti: Talep tahmini yapılması düşünülen zaman aralığı belirlenmektedir. Bu zaman aralığında tahminleme çalışması yapılmaktadır.

4. Talep tahmin yönteminin seçimi ve hata hesabı: Talep araştırılmasından elde edilmesi beklenen performansa göre tahmin yönteminin seçilmesi gerekmektedir.

5. Tahmin sonuçlarının geçerliliğinin araştırılması: Yapılan tahminleme sonucunda bulunan sonuç ile gerçek değerler arasındaki farkın tespiti edilmesi ve bu farkın nedenlerinin araştırılması aşamasıdır. Bu nedenlerden en önemlisi toplanan verilerin doğruluk derecesine bağlıdır.

5.2 Talep Tahminin Varsayımları

1. Tahminler çoğu zaman gerçek değerlerden farklı olabilir. Bu yüzden tahminler büyük çoğunlukla yanlıştır. Bunun nedeni ise, tahmin yapılan dönemde öngörülemeyen durumların meydana gelebilmesidir.

2. Tahminler sadece bir rakamdan oluşmamalıdır. Doğru tahminler, belli bir rakam yerine geçerlilik aralığı veya tahmin hatası dağılımı verebilmelidir.

3. Grup tahminleri daha doğrudur.

4. Tahminlerin doğruluğunun, tahmin yapılan süre ile ters orantılı olduğu düşünülmektedir.

İyi bir tahminin özellikleri aşağıdaki gibidir:

1. İyi bir tahminin gerçek değerlere yakın bir değere sahip olması gerekir.

2. Tahmin maliyetinin, sağlanan faydadan fazla olmaması gerekir.

3. Yazılı olmalıdır.

4. Güvenilir olmalıdır.

5. Tahminden yararlanan kişilerin anlayabileceği seviyede olmalıdır.

5.3 Talep Tahminin Yöntemlerinin Sınıflandırılması

Talep tahmin yöntemleri temel olarak üç sınıfa ayrılır. Bunlar nitel yöntemler, nicel yöntemler ve yapay zekâ tabanlı yöntemlerdir. 7 Nitel yöntemler çoğunlukla uzman kişilerin görüşlerine dayanırken, nicel yöntemler matematiksel ve istatistiksel hesaplamalara dayanır. Bu yöntemlerin yetersiz kaldığı durumda, yapay zekâ tabanlı yöntemler kullanılmaktadır.

5.3.1 Nitel yöntemler

Bilimsel yöntemlerin yerine verilere dayanarak hissi ve kişisel, yani yargısal olarak yapılan tahmin yöntemleridir. Tahmin etme yöntemi bilimsel verilere dayanmaması nedeniyle tahmin performansı diğerlerine göre düşüktür.

Bu yöntemin kullanılabilmesi için elde yeterli veri olmaması veya bu veriler mevcut ama bu verileri analiz edecek kadar uzun süre olmaması gerekir. Bu yöntemin en önemli özelliği, sezgisel yargıları da talep tahmini sürecine dahil edebilmesidir.

5.3.1.1 Uzman görüşlerinin alınması

Tahmin yapılması istenilen konu üzerinde uzmanlığı olan personelin tecrübelerine, bilgilerine ve sezgilerine dayanarak yapılan tahmindir. Bu uzman kişi mali işler, satın alma, satış, üretim veya yönetim kurulundan birisi olabilir. Kısa dönemlerde karar verilmesi isteniliyorsa bu yöntem kullanılabilir. Bu sayede verilerle uğraşma zamanından tasarruf edilebilir. Bu yöntem basit, uygulanması kolay ve düşük maliyetli olmasından dolayı daha avantajlı olduğu düşünülür. Fakat tamamen kişisel görüşlere dayandığından dolayı yanlış sonuçlara götürebilme olasılığı diğerlerine göre daha yüksektir.

5.3.1.2 Delphi tekniği

Bu teknik bir ürüne ait gelecekte oluşması beklenen talebin tahmin edilebilmesi için, uzman kişilerin yüz yüze görüşmeden ve arda tartışma yapmadan talebin gelecekteki değerine karar vermelerine ve uzlaşmalarına imkan veren bir yöntemdir. ABD’de RAND şirketinde 1950’li yıllarda çalışan Olaf Helmer ve Norman Dalkey adında 2

arařtırmacı tarafından dalphi tekniđi geliřtirilmiř ve uygulanmıřtır. Bu tekniđin amacı; gelecekle ilgili tahminlerde bulunmak, uzman grüşleri ortaya ıkarmak ve uzlařmanın sađlanmasıdır. Bu teknik, ođunlukla politik veya duygusal ortamlarda karar verme zorunda kalınıldığında veya kararların gl gruplar tarafından etkilenme olasılıđı olması halinde kullanılır. Bu tekniđi kullanan uzmanlara genellikle ardıřık anketler uygulanır. Genel olarak  zelliđe sahiptir:

- Katılımda gizlilik,
- Grup tepkisinin istatistiksel analizi,
- Kontroll geri besleme,

5.3.1.3 Anket yntemi

Hedef tketicilere, yeni bir rn piyasaya srlrken veya bu rnde deđiřiklik yapıldığında talebin tahmin edilebilmesi iin anket yaptırılması yntemidir.

Anket yolu ile geniř gruplara ulařmak, arařtırmayı byk gruplara dayandırmak daha kolaydır. Bu teknik, para, enerji ve zaman aısından arařtırmacıya avantaj sađlamaktadır. Fakat bu teknikte gvenilirlik aramak genellikle zordur. Anketlerden derinlemesine bilgi edinme kolay olmamaktadır. Kiřilere ait soruları aynı derecede anlamamaları veya cevaplarının aık olmamaları ve rastgele cevaplar vermeleri dezavantajları arasındadır. Arařtırmacının bunu kontrol etme imkanı da genellikle bulunmamaktadır.

5.3.1.4 Senaryo Analizi

Senaryolar geleneksel tahmin yntemlerinden farklı olarak alternatif gelecekler ortaya koymakta ve aynı zamanda ekonometrik modellerin dıřarında bıraktığı konuları ve kalitatif grüşleri de kapsamaktadır. Senaryo analizi, gerek kiřisel dřnce farklılıklarının, gerekse gelecek ile ilgili belirsizliklerin modellenmesine fırsat tanınması nedeniyle yaratıcılıđı teřvik etmektedir.

5.3.1.5 Satıř gc birleřimi

Satıř personellerinin kendi satıř blgelerindeki satıřların ne olacađını tahmin etmesidir. Tahminleme yaparken nceki satıř trendini dikkate alırlar. Sonra her birinin tahmini birleřtirilerek toplam tahmin elde edilir. Bu yntem, uzman personelin grřnn alınması yntemine benzemektedir. Burada satıř personeli

firma için yeni ve sektörü bilgisi az ise uygulanmaması gerekmektedir.

5.3.2 Nicel yöntemler

Nicel tahmin yöntemleri geçmiş dönemlere ait fiili olarak gerçekleşmiş talep değerlerini esas alan istatistiksel yöntemlerdir. Talebin oluşmasında etkili olan faktörlerin ile talep miktarları arasında bulunan ilişkinin gelecek sezonlar için de aynı şekilde eğilim göstereceği varsayımına dayanmaktadır. İstatistiksel yöntemlerle geçmiş sezon verileri incelenir ve bunlar esas alınarak gelecek dönemlere ait talep miktarları bulunur. Bu yöntemler zaman serileri analizi ve nedensel yöntemler olmak üzere ikiye ayrılır.

5.3.2.1 Zaman serileri analizi

Zaman serisi, geçmiş dönemlere ait veriler incelenerek, belli bir eğilim olup olmadığının belirlenip, geleceğe yönelik tahmin yapılmasıdır. Zaman sırasına konmuş geçmiş dönem verileridir. Zaman serisi analizinde, bu geçmiş dönem değerlerinin değişim biçimi araştırılır ve bu süreci temsil eden model kurulur. Bu modelle geleceğe yönelik talepler tahmin edilir.

Zaman serileri analizi çok geniş uygulama alanına sahiptir. Bu alanlar özellikle istatistik ve ekonomi gibi bilim dallarıdır.

Zaman serisini etkileyen beş ana faktör vardır. Bunlar; ortalama, eğilim, mevsimsel değişim, periyodik değişim, rastgele olaylardır.

1. Ortalama: Geçmiş döneme ait veriler, ortalama bir değer çevresinde gerçekleşir.
2. Eğilim (trend) : Sürekli olarak verilerin, aynı yönde değişen bir eğilim trend olarak tanımlanmaktadır. Bunun için regresyon modeli eğilim değişimini iyi gösteren bir matematiksel modeldir. Bu model bir doğru veya eğri olarak gösterilebilir.
3. Mevsimlik değişim: Mevsime bağlı olarak talebin değişmesidir. Mevsim olarak illa sıralı ayların olması şart değildir. Yakın taleplere sahip farklı aylarda mevsim olarak nitelendirilebilir. Örneğin, yılın değişik aylarında talebin artması veya azalması mevsim değişikliği olarak söylenebilir. 11 Mevsimlik bileşen genellikle üç aylık, aylık, haftalık vb. sınıflandırılmış verilerden oluşur. Düzenli olarak yinelenen değişim eğilimine sahiptir.
4. Konjonktürel Değişim: Geçmiş döneme ait verilerin, mevsimsele göre daha uzun

zaman aralıklarında oluşan değişimlerine denmektedir. Genellikle kararsızlıklar veya değişen ekonomik şartlara bağlı olarak bir yıldan fazla süren değişimdir. Ekonomideki büyük çaplı değişimler sonucunda talepte de büyük çaplı değişim olur.

5. Rastgele Olaylar: Genellikle düzensiz ve anlaşılması zor olan olaylardır. Bu olaylar sonucunda talep oluşmaktadır. Genellikle hava değişimleri (sel, deprem vs.), grevler, savaşlar, savaş söylentileri, yasal değişiklikler gibi zamanlanmayan ve öncede kestirilemeyen olayların yol açtığı dalgalanmalardan meydana gelir. Örneğin; depremde yıkılan konutlar sonucunda, konut talebinin artmasıdır.

Zaman serileri analizinde aşağıdaki yöntemler uygulanmaktadır:

1. Basit aritmetik hareketli ortalama yöntemi: Bu yöntemde son n döneme ait değerlerin ortalaması, bir sonraki döneme ait tahmin edilmesi istenen değer (\hat{Y}) olarak alınır. Matematiksel ifadesi aşağıdaki gibidir. (Denklem 5.1)

$$\hat{Y}_i = \sum_{i=1}^n = \bar{Y} \quad (5.1)$$

Dönem sayısını belirlemek için genellikle deneme yanılma yöntemi kullanılmaktadır. Her yeni dönemde, en eski döneme ait değer ortalamadan atılarak son n dönemin değerlerinin ortalaması alınır. Hesaplar sonucu bulunan bu ortalama, bir sonraki değer tahmini değeridir.

2. Hareketli ortalama yöntemi: Hareketli ortalama yönteminde, Y değişkeninin bir sonraki dönemde alacağı tahmini değer, o değişkenin geçmiş n dönemdeki ortalaması alınarak bulunur. Matematiksel ifadesi Denklem (5.2)'de gösterilmektedir.

$$\hat{Y}_i = \frac{Y_{i-1} + Y_{i-2} + \dots + Y_{i-n}}{n} \quad (5.2)$$

Eğer belirli dönemlerin verileri (örneğin en yakın geçmiş dönemler) gelecek dönemler için kesin bir kanı veriyorsa, değerler hesaplanırken son dönemdeki verilere daha fazla ağırlık verilir.

Hareketli ortalamalara dahil edilebilecek gözlem sayısı, tahmin yapacak kişi tarafından belirlenir ve her zaman sabit kalmaktadır. Bu yöntem her yeni değer ile birlikte yeni bir ortalamaya sahip olur.

3. Ağırlıklı hareketli ortalamalar yöntemi: Bu yöntemde ürünün talebine etki eden dönemlere daha büyük ağırlıklar verilerek, bu dönemlerin ortalamada daha fazla

etkisinin olması sağlanabilir. Bunun yanı sıra zaman serisini oluşturan veriler arasında ortalamanın üstünde ve altında değerler varsa, bu değerlerin ağırlıkları düşürülerek tahmin değeri üzerindeki etkisinin azaltılması sağlanabilir. W ağırlık değerlerini, y ise gerçekleşen bağımsız değişken değerini göstermektedir. Ağırlıklı ortalama yönteminin formülasyonu yer almaktadır (Denklem 5.3).

$$\hat{Y} = \frac{W_1 * y_t + W_2 * y_{t-1} + \dots + W_n * y_{t-n+1}}{W_1 + W_2 + \dots + W_n} \quad (5.3)$$

Wn. n. dönemde gerçekleşen talebe verilen ağırlık olmak üzere verilecek olan ağırlıkların doğru belirlenmesi önemlidir. Bu değerler doğrusal olarak belirlenebilir. Bunun sonucunda geçmiş taleplere doğru düzgün bir azalış gösterecektir.

Hareketli ortalama yönteminde son kaç periyodun hesaplamaya dahil edileceği, tahmin edicinin kararına bağlıdır. Çoğunlukla deneme yanılma yöntemi ile belirlenir. Basit aritmetik hareketli ortalama yönteminde hesaplamaya dahil edilen son n dönemin değerleri eşit ağırlıklı idi. Bu iki durumun eksiklerini ortadan kaldırmak için aşağıdaki yöntem kullanılmaktadır.

a. Üssel ağırlıklandırılmış hareketli ortalama yöntemi: Bu yöntemde geçmiş zaman dönemlerine ait ortalama talep ile mevcut döneme ait talebi belirli oranlarda 13 tekrar ağırlandırarak bir sonraki dönemin talebini hesaplar. Metodun kullanılabilmesi için geçmiş dönemlerin talep ortalaması ve mevcut dönemin talep değeri yeterlidir. Bu yöntemde ait formülasyonlar aşağıdaki gibidir (Denklem 5.4).

$$X = \frac{1}{\left(\frac{n}{2} - 1\right)}$$

$$\hat{Y} = \left[(1 - X) * \frac{\sum_{n=1}^{t-1} Y_n}{n} \right] + \left[(1-X) * Y_t \right] \quad (5.4)$$

X değeri en son dönemle önceki dönemler arasındaki ağırlıklandırmayı belirleyen katsayıdır. n dönem sayısını ve t ise ilgili dönemi ifade eder. Metot en son dönem ağırlığını önceki dönemlerden ayrı tutarak iki kez ağırlıklandırma yapar.

b. Üssel düzgünleştirme yöntemleri: Basit üssel düzgünleştirme yöntemi, holt lineer metodu, holt- winter mevsimlik tahmin yöntemi, box jenkins tahmin yöntemi,

Otoregresif modeller - AR(p) modelleridir, hareketli ortalamalar, otoregresif hareketli ortalama ve otoregresif entegre hareketli ortalama yöntemleridir. Aşağıda bu yöntemler ayrıntılı olarak anlatılmıştır:

1. Basit üssel düzgünleştirme yöntemi: Bu yöntem geçmiş dönem verilerine eşit ağırlıkların verilmediği yöntemlerden biridir. Basit ve ağırlıklı hareketli ortalama yöntemlerinden farkı, bir döneme ilişkin tahmini talep miktarının bu dönemden önce gelen tüm dönemlerde gerçekleşmiş olan talep miktarlarına bağlı olarak belirlenmesini öngörmektedir. Bir döneme ait talebi bulurken, bu dönemden önceki dönemlere ters orantılı ağırlıklar verir. Bu sayede en yakın geçmişte gerçekleşen talep miktarı, yapılan tahmini en fazla etkileyen veri olmaktadır. En geçmiş zamandaki talep miktarı ise, bulmak istediğimiz güncel talep miktarını en az etkileyen veri olmaktadır. Denklem (5.5)'da bu yöntemin formülasyonu yer almaktadır.

$$\hat{Y}_{t+1} = \hat{Y}_t + \alpha (y_t - \hat{Y}_t) \quad (5.5)$$

Bu formüle farklı olan α katsayısı 0 ile 1 arasında değer alan düzgünleştirme katsayısıdır. Bu katsayı dönemlere verilen ağırlık değerini etkilemektedir. α büyüdükçe son dönemlere daha çok ağırlık verilir. $(y_t - \hat{Y}_t)$ ifadesi bir önceki deneme ait tahminin hata değeridir. Eğer bu hata pozitif gerçekleşmişse, tahminden büyüktür ve düzgünleştirme bir sonraki değeri arttırıcı etki yapar. α değeri denemeler yapılarak en uygunu bulunur. Genellikle 0.05 ile 0.30 arasında seçilmelidir.

2. Holt lineer metodu: Bu yöntemi, zaman serisinin bir trende sahip olması durumunda geleceğe yönelik tahmin yapmak için kullanılabilir. Yöntem, Holt tarafından 1957 yılında, basit üssel düzgünleştirme yöntemine trend bileşeninin eklenmesiyle geliştirilmiştir.

3. Holt - winter mevsimlik tahmin yöntemi: Zaman serisinin trend bileşeni ile birlikte mevsimsellik de içerdiği durumlarda kullanılır. Bu durumda talep, doğrusal bir yapı göstermemektedir. Tahmin formülasyonunda trend bileşeni ile birlikte mevsimsellik bileşeni de vardır. Bu yöntemde ait formüller denklem 5'da yer almaktadır.

$$\hat{Y}_t = \alpha * y_t + (1-\alpha)(\hat{Y}_{t-1} + b_{t-1})$$

$$b_t = \beta (\hat{Y}_t - \hat{Y}_{t-1}) + (1-\beta)b_{t-1}$$

$$Y_{t+m} = \hat{Y}_t + b_t m \quad (5.6)$$

Burada, ilk denklemde \hat{Y}_t değeri, Y_t değerine bir önceki dönemin trendi (b_{t-1}) ile bir önceki dönem düzgünleştirilmiş değerinin ilave edilmesiyle bulunmaktadır. İkinci denklem son iki dönem düzeltme değerlerinin farkı şeklinde trendi güncellemektedir.

Son denklem ise y_{t+m} tahmini, bir önceki dönem düzgünleştirilmiş değerine (\hat{Y}_t) m kadar t dönemi trendinin (b_t) ilavesiyle yapılmaktadır. α ve β , düzeltme sabitleridir.

4. Box - Jenkins tahmin yöntemleri: Bu yöntem 1970 li yıllarda temelleri atılan, durağanlığı, deterministik bileşen bilgisini ve geleceğe ilişkin tahminleri bir arada ortaya koyduğu için tercih edilen bir yöntemdir.

Bu yöntemin, temelinde durağan olan ya da durağanlığı sağlanmış olan bir zaman serisine ilişkin birçok olası model arasında uygun ARIMA modelinin belirlenmesi, parametrelerin bulunması ve modelin uygunluğunun değerlendirilmesi olarak üç aşaması yer almaktadır. Kurulan model uygunluk testlerini geçemezse, aşamalar yeniden baştan başlatılır ve en iyi dereceyi veren modeli buluncaya kadar devam edilir. Bu bulunan model nihai model olarak adlandırılır ve tahminde bu model kullanılmaktadır. Bir değişkene ilişkin yapılacak tahmin, kendi gecikmeli değerleri, hata terimleri ya da her ikisinin birleşimi ile yapılmaktadır.

Bu yöntem ile bir zaman serisini modelleyebilmek için zaman serisinin durağan olması gerekmektedir. Bunun için, zaman serisinin ortalamasında ve varyansında sistematik bir değişim olmaması lazımdır. Eğer bir seri sabit bir büyüme ya da eğilim gösteriyorsa, bu yapıdaki seriler durağan hale dönüştürülmeden modelleme yapılamaz.

Bu metotta üç model vardır: Bunlar Otoregresif (AR) Süreç, Hareketli Ortalama (MA) Süreci ve bunların birleşiminden oluşan Otoregresif Hareketli Ortalama (ARMA) Süreci'dir. Durağan olmayan bir seri için fark alınması gerektiğinde ise

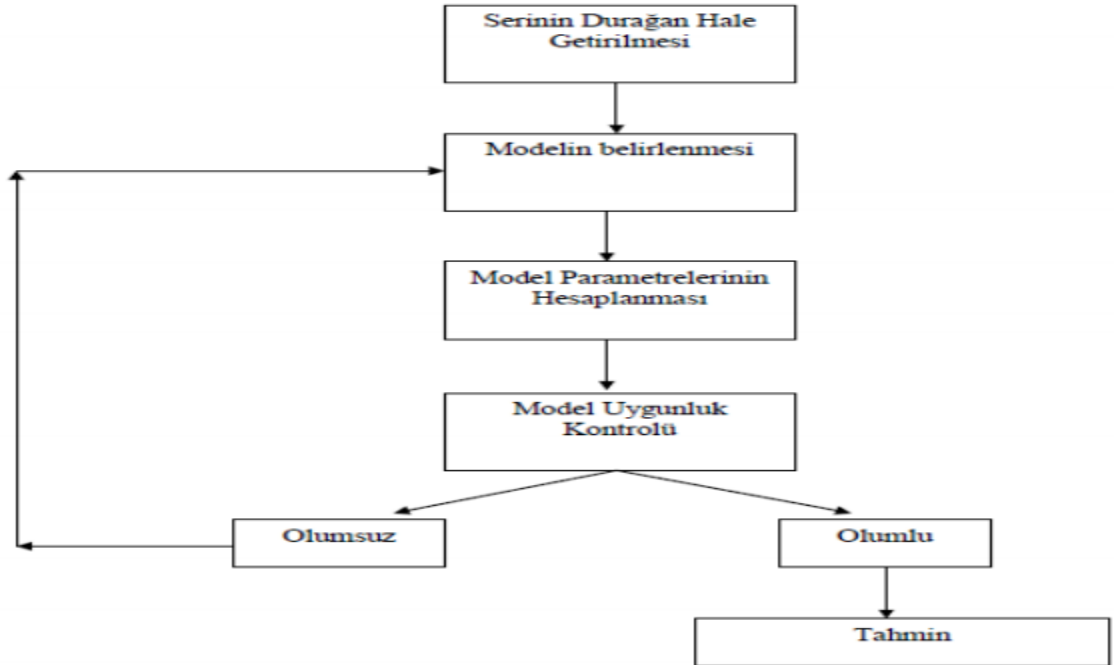
ARMA süreci yerine ARIMA süreci kullanılır. ARIMA Süreci, fark alınarak durağan hale getirilmiş otoregresif hareketli ortalama sürecini ifade etmektedir.

Gözlem değerlerinin rastsal ve serinin de stokastik bir süreç olduğu varsayılır.

Bu yaklaşımda, model oluşturma ve tahmin genel olarak dört aşamada oluşmaktadır. Bunlar aşağıdaki gibidir:

1. Modelin belirlenmesi (identification): Zaman serisine uygun Box-Jenkins modeli bu aşamada belirlenir.
2. Modelin parametrelerinin kestirimi (estimation): Belirlenen modele ilişkin parametrelerin tahmin edildiği aşamadır.
3. Modelin uygunluğunun araştırılması (diagnostig checking): Modelin veri setine uygunluğunun istatistiksel yöntemlerle test edildiği aşamadır. Model uygun bulunursa bir sonraki aşamaya geçilir, uygun bulunmazsa ilk aşamaya yeni modelin belirlenmesine geri dönlür.
4. Tahmin (forecasting): Bulunan en uygun model tahmin için kullanılır.

Box Jenkins metodolojisi Şekil 5.1' deki gibi gösterilmektedir.



Şekil 5.1. Box jenkins metodolojisi (Olgun, 2009)

5. Otoregresif modeller - AR(p) modelleri: Bu modellerde, p değeri geçmiş dönem sayısını vermektedir. Model, p dönemdeki zaman serisi değerlerinin ağırlıklı 17

toplamının ve rassal hata değerinin bir fonksiyonudur. AR(p) modelinin genel olarak gösterimi aşağıdaki Denklem (5.7)'daki gibidir:

$$Y_t = \mu + \phi_1 * Y_{t-1} + \phi_2 * Y_{t-2} + \dots + \phi_p * Y_{t-p} + \epsilon \quad (5.7)$$

Formülde μ değeri serinin ortalamasını verir ve ϕ_1, \dots, ϕ_p otoregresif parametrelerini göstermektedir. ϵ değişkeni serinin hata değişkenini temsil eder.

6. Hareketli ortalamalar - MA (q) modelleri: Bu modelde, Y_t değeri serinin geriye doğru q dönem geçmiş hata terimlerinin ve ortalamasının doğrusal bir fonksiyonudur.

Bu modelin genel gösterimi Denklem (5.8)'deki gibidir:

$$Y_t = \epsilon_t - \phi_1 * \epsilon_{t-1} - \phi_2 * \epsilon_{t-2} - \dots - \phi_q * \epsilon_{t-q} \quad (5.8)$$

Burada ϵ_t ler korelasyonsuz tesadüfi, sıfır ortalama ve sabit varyansa sahip hatalardır.

7. Otoregresif hareketli ortalama modeli ARMA (p,q): Bu model, AR ve MA modellerinin bir birleşimidir. Sadece AR veya sadece MA modelleri ile modelleyemeyen süreçlerde kullanılabilir. ARMA modelleri en genel durağan stokastik süreç olup, geçmiş gözlemlerin ve geçmiş hata terimlerinin doğrusal bir fonksiyonudur. Formülasyon gösterimi Denklem (5.9)'deki gibidir.

$$Y_t = \delta + \phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p} + \epsilon_t + \phi_1 \epsilon_{t-1} + \dots + \phi_q \epsilon_{t-q} \quad (5.9)$$

Burada kesme terimi δ , Y_t nin ortalama ile ilgili hatalar ϵ_t olarak gösterilmektedir. Eğer bu süreç durağan ise tüm dönemler için sabit bir ortalamaya sahiptir.

8. Otoregresif entegre hareketli ortalama modeli ARIMA (p,d,q): Bu model, zaman serilerinin durağan olduğu varsayımına dayanır. Birçok 18 durağan olmayan zaman serisi bir veya daha fazla fark alınarak, durağan zaman serisi haline dönüştürülür. D kere fark alınarak durağan hale getirinle bu seriye durağan olmayan entegre süreç denilir.

Durağan bir zaman serisinde, ortalama, varyans ve otokorelasyon fonksiyonu sabittir. Zaman serileri durağan değilse, belirli bir trend içermektedir. Box Jenkins modellerinde uygun modelin belirlenmesi önemli bir süreçtir. Modelin belirlenmesi

(p,d,q) parametrelerinin de belirlenmesi demektir. D değeri, serinin artan veya azalan yapısı varsa ve bu yapı doğrusal ise d=1, eğrisel ise d=2 alınır. Fakat p ve q değerleri otokorelasyon ve kısmi korelasyon fonksiyonları ile belirlenebilir. Bu modele ait formülasyonlar Denklem (5.10)'de yer almaktadır.

$$m = \frac{\sum_{t=1}^T Y_t}{T}$$

$$\rho = \frac{\sum_{t=1}^{T-k} (Y_t - m)(Y_{t-k} - m)}{\sum_{t=1}^T (Y_t - m)^2}$$

(5.10)

m değeri serinin ortalamasıdır. Korelasyon değeri (ρ) de k dönemin ilişkisini verir. Kısmi korelasyon ise, zaman serisindeki iki nokta arasındaki ilişkiyi belirler. Kısmi otokorelasyon, otokorelasyondan türetilir.

5.3.2.2 Nedensel yöntemler

Nedensel yöntemler, tahmin edilmek istenen etkeni, kendisini etkileyen faktörler ile ilişkilendirerek, tahminlerin bu faktörlerdeki değişimlere bağlı olarak yapılmasını amaçlayan yöntemlerdir. Talep ile talebi etkileyen etkenler arasında neden-sonuç ilişkisi vardır.

Nedensel yöntemlerde genellikle, bir değişkenin gelecekteki değeri tahmin edilmesinin dışında, bu değişkeni etkileyen faktörler arasında bulunan ilişkilerin açıklama yapılmasına çalışılmaktadır. Bağımlı değişken ile ilişkisi olan değişkenlerin belirlenmesi ve bu ilişkinin bir matematiksel modelinin bulunması amaçlanmaktadır. Bu yöntemler arasında en çok tercih edilenleri, regresyon analizi ve korelasyon analizidir.

1. Regresyon analizi: Regresyon analizi bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi inceleyen bir yöntemdir. Eğer bağımsız değişken sayısı bir ise tek değişkenli regresyon analizi, birden fazla ise çok değişkenli (çoklu) regresyon analizi olarak adlandırılır.

Regresyon yönteminde çıktı Y_x , sistem girdileri ile X_1, X_2, \dots, X_n arasındaki ilişki incelenir. Bu bağımsız ve bağımlı değişkenler arasındaki ilişki doğrusal veya eğrisel olabilmektedir.

Bağımsız değişkenler belirlendikten sonra, verilere dayanarak bağımlı değişken ile bağlantılarını açıklayan matematiksel model geliştirilir ve bu model ele alınan bağımlı değişkenin tahmini değerini bulmak için kullanılır.

Regresyon analizin en büyük özelliği, bu yöntemle geliştirilen modelin işletmenin karar mekanizmasına (yöneticilerine) çeşitli alternatif etkenlerin sonuç üzerinde değerlendirme yapma olanağı sağlamasıdır. Bu nedenlerden regresyon analizi çoğu firmada kullanılmaktadır.

**Tek değişkenli regresyon modelinin formülasyonu Denklem (5.11)'deki gibidir:

$$Y_i = \beta_0 + \beta_i X_i + \epsilon_i \quad (5.11)$$

Bu formülde, Y_i tahmin değeri, X_i bağımsız değişkenin doğrusal bir fonksiyonu olarak gösterilmektedir. β_0 , doğrusunun Y eksenini kestiği noktayı, β_1 , doğrunun eğimini, ϵ_i ise i . gözleme ait hata bileşenini vermektedir. Burada β_0 ve β_1 değerleri, en küçük kareler yöntemi ile bulunmaktadır.

Gerçek uygulamalarda, β_0 ve β_1 değerleri bilinmiyorsa, ana kütlede örnekler alınarak bunların tahminçileri olan b_0 ve b_1 kullanılarak (5.12) no'lu denklem yazılır:

$$y = b_0 + b_i * X_i + e \quad (5.12)$$

**Ana kütle ve örnek için çoklu regresyon denklemleri (5.13) nolu denklemlerde gösterilmektedir.

$$Y_i = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \beta_n X_n + \epsilon$$


$$Y = b_0 + b_1 X_1 + b_2 X_2 + b_n X_n + e \quad (5.13)$$

En küçük kareler yönteminde, ϵ_i hata bileşeninin karesini minimum yapan doğru denkleminin bulunması amaçlanmaktadır. Bu denklemin bulunmasından sonra, sonraki dönemlerin tahmini yapılabilmektedir. β_0 ve β_1 değerleri aşağıdaki (5.14) denklemlerle bulunmaktadır:

$$\beta_1 = \frac{n \sum XY - (\sum X \sum Y)}{n \sum X^2 - (\sum X)^2}$$

$$\beta_0 = \frac{\sum Y}{N} - \beta_1 \frac{\sum X}{n} \quad (5.14)$$

β_0 ve β_1 değerleri kullanılarak gelecek dönemlere ait Y değerleri tahmin edilebilmektedir. Şekil 5.2.'de en küçük kareler yöntemine ait şekil yer almaktadır.



Şekil 5.2. En küçük kareler yöntemi (Yücesoy,2011)

2. Korelasyon yöntemi: Korelasyon analizi değişkenler arasındaki ilişkinin derecesini ortaya koymaktadır. Korelasyon bir değişkenin değeri değişirken diğer bir değişken bununla doğrusal ilişkili olarak değişiyorsa korelasyon vardır denilebilir. Korelasyon yöntemi, doğrunun uygunluğunu ölçmektedir. Başka bir ifadeyle, denklemin ilişkiyi ne ölçüde tanımladığını göstermektedir. İlişki ne derece güçlü ise, oluşturulan tahminlerde o derece iyidir.

Değişkenler arasında bulunan mevcut ilişkinin betimlendiği için betimleyici araştırmadır. Bir "korelasyon katsayısı" bularak arasındaki ilişkiyi betimleyebiliriz. Eğer değişkenler arasında doğrusal bir ilişki yoksa $R=0$ çıkar.

Aşağıdaki Denklem (5.15)'de y ile x değerler beraber artıyorsa pozitif, x arttığında y düşüyorsa negatif bir değer alır. Denklem (5.15)'de korelasyon katsayısının nasıl

bulunduğu gösterilmiştir. R korelasyon katsayısını göstermektedir.

$$R = \frac{n \sum X_i Y_i - \sum X_i \sum Y_i}{\sqrt{[n \sum X^2 - (\sum X)^2] [n \sum Y^2 - (\sum Y)^2]}} \quad (5.15)$$

Korelasyon katsayısının aldığı değerler aşağıdaki gibi yorumlanır.

Çok yüksek korelasyon	:	0.90 - 1.00 :
Yüksek korelasyon	:	0.70 - 0.90
Normal korelasyon	:	0.40 - 0.70 :
Düşük korelasyon	:	0.20 - 0.40 :
Çok düşük korelasyon	:	0.00 - 0.20 :

5.3.2.3 Yapay zeka tabanlı yöntemler

Yapay zeka, insanın düşünme yapısına göre davranan ve insan gibi düşünebilen bilgisayar işlemlerini geliştirme olarak tanımlanabilmektedir. Başka bir ifadeyle, insana özgü algılama, görme, düşünme, karar verme, bilgi edinme gibi özelliklere sahip olan bilgisayarlardır.

Yapay zeka tabanlı yöntemler, genellikle karmaşık problemlerin çözümünde güçlü yöntemler olarak bilinmektedir. Talep tahmininde en sık rastlanan yapay zeka yöntemleri, yapay sinir ağları, bulanık mantık ve genetik algoritmalarıdır. Bu çalışmada yapay sinir ağları kullanılmıştır.

1. YSA: YSA, yapay zeka yöntemleri arasında en çok kullanılan yöntemlerden birisidir. Yapay sinir ağları örneklerden öğrenebilme ve genelleme yapabilme özelliklerine sahip olduğu için bu yönteme çok esnek ve güçlü araçların olması özelliği sağlanmıştır.

2. Bulanık mantık: Bu kavram, ilk defa 1965 yılında Zadeh tarafından yapılan çalışmalar sonucunda ortaya atılmıştır. Bu çalışmalarında, girdi verilerinin farklı kümelerdeki farklı üyelik derecelerinden bahsetmiş ve girdinin çıktıya dönüşümünün bu kümeler aracılığıyla yapılabileceğinden söz etmiştir. Bu yöntem özellikle deneyimlere dayalı verilerin ya da sayısal olarak ifade edilemeyen verilerin yorumlanmasında yaygın olarak kullanılmaktadır.

Bulanık küme, farklı üyelik derecesine sahip öğelerin olduğu bir kümedir. Bulanık

küme, klasik küme teorisindeki evet-hayır olana ikili üyelik kavramını ikiden fazla kısmi üyelik içeren kavrama dönüştürmek anlamına gelmektedir.

3. Genetik algoritma: Genetik algoritmalar (GA) günlük hayatta karşılaştığımız çözümü olanaksız ya da çok zor olan karmaşık problemlerin hesaplanmasında kullanılmaktadır. Genetik algoritma tabanlı yaklaşım kullanılarak veri yığınlarından modeller elde edilmektedir. Talep tahmininin bulunmasında yararlanılan bir yöntemdir.

5.4 Yapay Zeka Tabanlı Yöntemler

Tahmin yöntemlerinin hangisi kullanılırsa kullanılsın %100 doğru değeri vermez. Gelecek %100 biliniyorsa zaten bu tahmin olmaz. Bu nedenle her tahminde belirli bir hata oranı mevcuttur. Çeşitli tahmin modelleri arasında, bir tanesini seçme aşamasında en yaygın kabul gören kriterlerden biri de modelin verilere uyum göstermesi, modelin öngörü başarısının yüksek olmasıdır. Modellerin öngörü başarılarının karşılaştırılması amacıyla çeşitli kriterler mevcuttur. Bu kriterlerden en önemlisi, tahmin doğruluğudur. Tahmin yönteminin doğruluğu, tahmin edilen hataların analiz edilmesiyle ölçülür. Tahmin hatası, gözlenen gerçek değerler ile tahmin edilen değerler arasındaki farktır. Herhangi bir periyottaki tahmin hatası Denklem (5.16)'de gösterilmektedir.

$$e_t = Y_t - F_t \quad (5.16)$$

Y_t ; gözlenen gerçek değeri, F_t modelin ürettiği değeri göstermektedir. En çok kullanılan tahmin doğruluğu ölçüm kriterleri aşağıdaki gibidir:

1. Ortalama hata kareleri (Mean Squared Error- MSE): Hata kareleri ortalaması, talep tahminlerinin doğruluk hesaplanmasında sıklıkla kullanılır. Bu yöntem hataları işaretlerden arındırır ve sadece büyüklüklerine bakar. Denklem (5.17)'de gösterilmektedir.

$$MSE = \frac{\sum(Y^T - Y^G)^2}{t-k} \quad (5.17)$$

Burada Y^T , tahminlenen değeri, Y^G ise gerçekleşen değeri göstermektedir. t , tahmin sayısını, k ise verilecek katsayıyı göstermektedir.

2. Kök ortalama hata kare (Root Mean Squared Error – RMSE): Ortalama hata kareleri yöntemiyle bulunan hatanın karekökünün alınmasıyla bulunur. Denklem (5.18)'de yer almaktadır.

$$RMSE = \sqrt{\frac{(Y^T - Y^G)^2}{t-k}} \quad (5.18)$$

3. Ortalama mutlak hata (Mean Absolute Error – MAE): Bu yöntem, hata değerlerinin mutlak değerleri alınarak işaretlerden arındırılır. Böylelikle hata değerleri talep değerlerine uzaklıkları ile hesaplanmış olur. Denklem (5.19)'de gösterilmektedir.

$$MAE = \frac{\sum |Y^T - Y^G|}{t-k} \quad (5.19)$$

4. Ortalama mutlak yüzde hata (Mean Percentage Absolute Error- MAPE): Bu yöntem, oluşan hataları yüzdesel olarak ifade eder. Böylelikle hataların birbirleri ile kıyaslanmasını sağlar. Denklem (5.20)'de gösterilmektedir.

$$MAPE = \sum \frac{|Y^T - Y^G|}{Y^G} \cdot \frac{100}{t} \quad (5.20)$$

5. Kök ortalama yüzde hata kare (Mean Squared Percentage Error- MSPE): Kök ortalama yüzde hata kareleri ile ilgili formül Denklem (5.21)'de gösterilmektedir.

$$MSPE = \sqrt{\frac{1}{t-k} \sum \frac{(Y^T - Y^G)^2}{Y^G}} \quad (5.21)$$

Aşağıda formüllerde yer alan simgelerle ilgili açıklamalar mevcuttur:

- T : Durağan hale getirilen serinin gözlem sayısı
- K : Modelde tahmin edilen parametre sayısı
- YT : Modelin tahmin değeri
- YG : Serinin gerçek değeri

6. UYGULAMA

Bu uygulamada eğitimi yayıncılığı sektöründeki bir firmanın yıllık satış verilerinden yola çıkarak yapay sinir ağlarının Matlab (R2008A Sürümü) yazılımı ile gerçekleştirilmiştir.

Eğitim Yayıncılığı sektörüne ait bir firmanın önceki senelerin satış tutarları üzerinden, gelecek sene için satış tahminleri yapılmaktadır. Yapılan bu il bazlı satış tahminler dikkate alınarak yıllık bütçeler hazırlanmakta ve ana üretim planı oluşturulmaktadır. Fakat yapılan tahmin değerleri ile fiili gerçekleşen tahmin değerleri her zaman aynı olmamaktadır. Bu da üretim planlamasından ham malzeme satın almasına kadar her süreci olumsuz etkilemektedir. Geçmiş yılların satış tahminleri üzerine yapay sinir ağları yöntemi veri yapısına uygun YSA modeli belirlenerek gelecek ayların satış tutarları tahmin edilmeye çalışılmıştır. Eğitim yayıncılığı satışını etkileyen firma dışı faktörlerin belirlenmesi aşamasında Uzman arkadaşların görüşlerine başvurulmuştur.

Bu bölümde yapay sinir ağlarının bu problem için uygulama aşamaları anlatılmış ve satış talebini etkileyen faktörler incelenmiştir. Yapay sinir ağları ile yapılan tahmin, çoklu regresyon analizi ve zaman serileri analizleriyle yapılan çalışmalar ile karşılaştırılarak tahminleme performansı test edilmiştir.

Bu çalışma ile il bazlı satış tahminlerinin ve bunu etkileyen faktörlerin belirlenmesi amaçlanmıştır. Bu faktörlerin büyük bir çoğunluğu, satışını da etkileyen faktörler olması pek tabidir. Yurt içi satış talebini etkileyen firma dışı faktörler aşağıdaki gibidir:

1. Satış Hacmi: Satış tutarları
2. Öğrenci Sayısı:
3. Hane Eğitim Harcaması
4. Dolar Kuru
5. Müşteri Sayısı

6. Tüketici Fiyat Endeksi (TÜFE)

7. Üretici Fiyat Endeksi (ÜFE)

Bu faktörlere ek olarak iki faktörde yayın satışlarını etkilemektedir. Bunlardan ilki Milli Eğitim Bakanlığının eğitim politikalarıdır. Diğer de Yerel Yönetimlerin (Valilik, Kaymakamlık, Belediyeler vb) yaptıkları kültürel faaliyetler, Sınavlara hazırlık çalışmalar yayın satışlarını ciddi olarak etkilenmektedir. Bu iki faktörün geçmiş dönemlere ait veri toplanma olanağı olmadığı için uygulamaya alınamamıştır. Bu çalışmada kullanılan verilerin çoğu Türkiye İstatistik Kurumu (TÜİK), Merkez Bankası verilerinden derlenmiştir. Girdi ve çıktı verilerini gösteren tablo Ek1’de sunulmuştur.

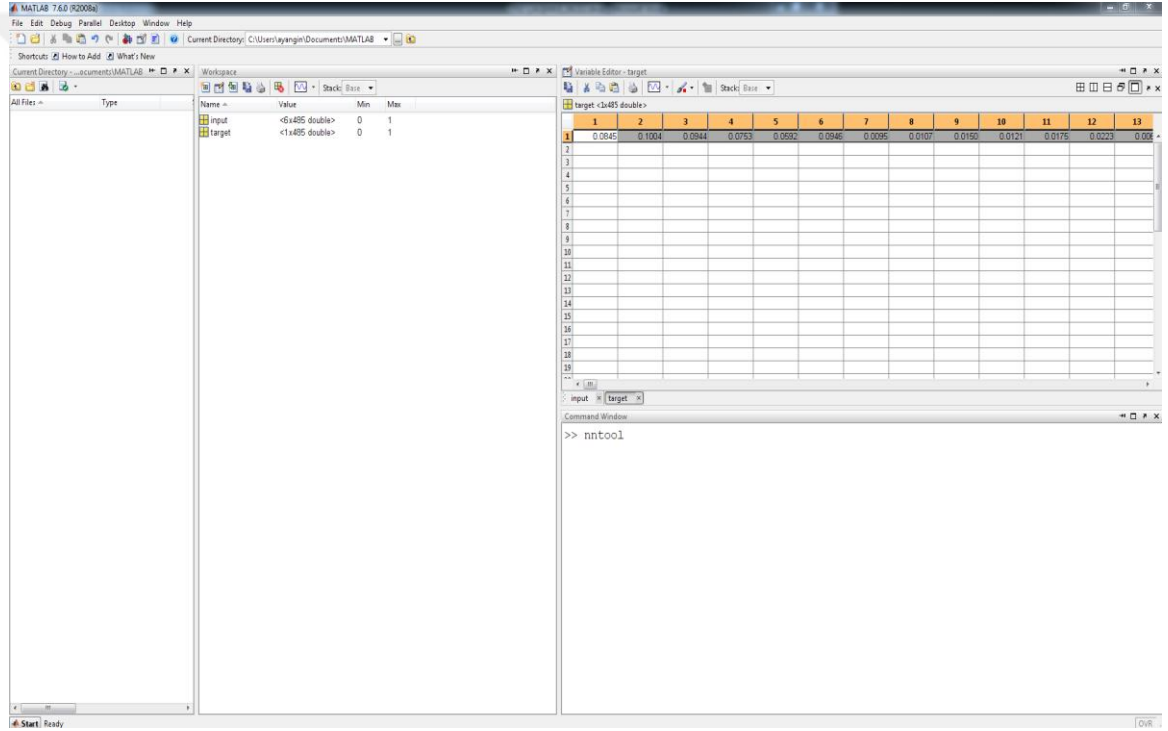
6.1 Yapay Sinir Ağı Mimarisi

Talep tahmininde en çok kullanılan yöntem, geri yayılım algoritmasıdır. Bu nedenle yapılan çalışmada çok katmanlı ileri beslemeli geri yayılım algoritması kullanılmıştır.

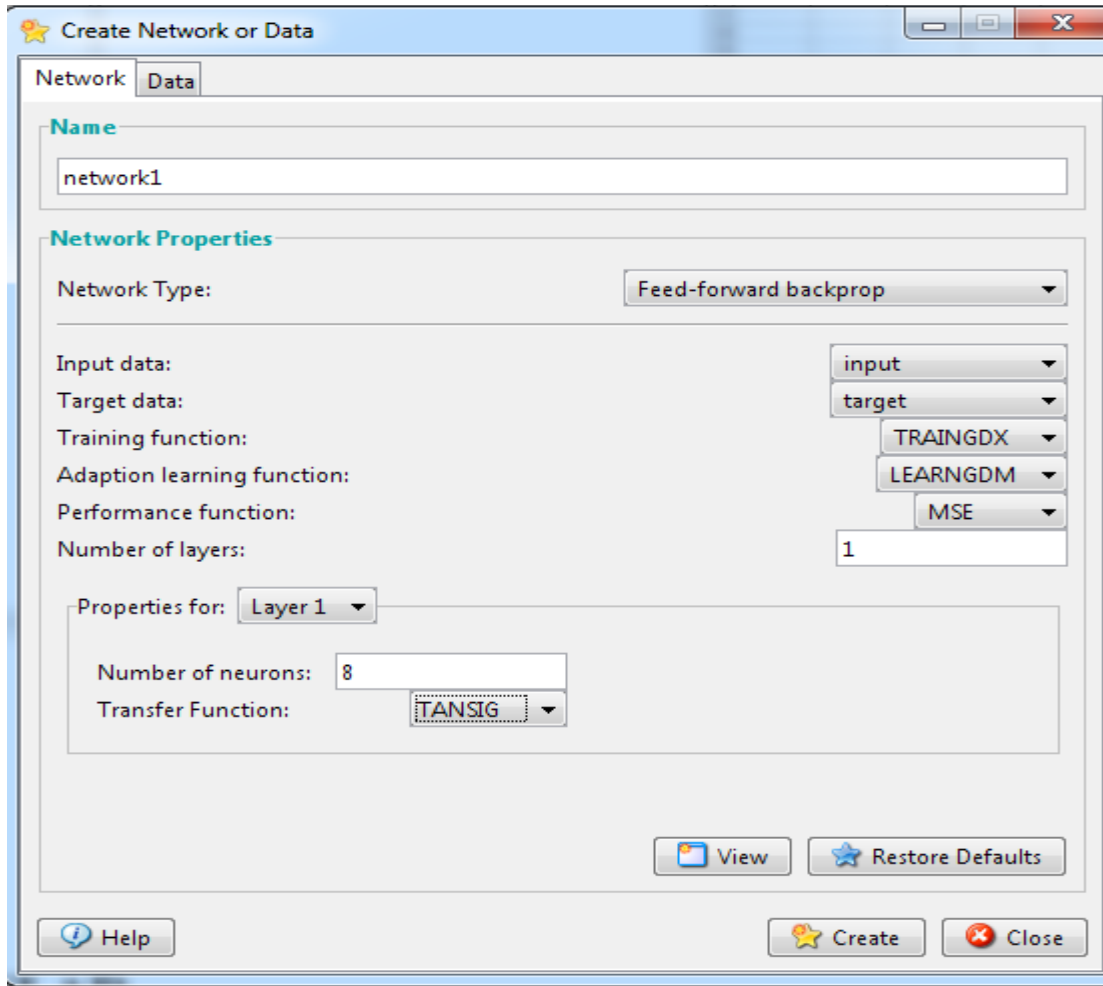
Normalizasyon tekniği olarak en çok kullanılan D_Min_Max yöntemi kullanılarak, tüm veriler [0.1, 0.9] arasında normalize edilmiş ve programa aktarılmıştır. Çalışma kapsamında oluşturulan tüm modeller giriş katmanı, çıktı katmanı ve gizli katmandan oluşmuştur. Girdi katmanı sekiz hücreden, çıktı katmanı ise bir hücreden oluşmaktadır. Gizli katmanda ise farklı sayılarda hücre bulunabilir, bunun için ileriki kısımlarda en uygun hücre sayısı bulmak için denemeler yapılmıştır. Yapay sinir ağı modellenmesinde gizli hücre sayısını elde etmek için “geometrik piramit kuralı” olarak adlandırılan bir yöntem kullanılır. Bu kurala göre, girdilerden çıktılara doğru hücre sayısının azalması gerektiği varsayımına dayanır. Gizli hücre sayısı piramit kuralı gereği, girdi hücre sayısının iki katı olan on altıyı geçemez. Ayrıca bu sayı, girdi hücre sayısı ile çıktı hücre sayısının çarpımının karekökünden de az olamaz. Çok sayıda farklı denemeler yapılmıştır.

6.2 Yapay Sinir Ağı Matlab Uygulamaları ve Eğitilmesi

Ağın eğitilmesi için Matlab R2008A programının Neural Network uygulaması kullanılmıştır. Öncelikle Matlab uygulamasında Workspace kısmına normalize edilmiş olan eğitim girdi ve çıktı verileri girilir. Daha sonra yapay sinir ağı tanımlamaları yapmak için Matlab “Network” kısmında oluşturmak istediğimiz ağ ile ilgili ağ tipi, eğitim girdi- çıktı verisi, eğitim ve öğrenme algoritmaları, performans fonksiyonu, katman sayısı, gizli hücre sayısı, nöron sayısı ve aktivasyon fonksiyonu girişleri yapılır ya da açılan butonlardan seçim yapılır. İlgili yerler doldurulduktan sonra “ Create” butonuna basılarak ağ yaratma işlemi gerçekleştirilir. Matlab giriş ekranı Şekil 6.1 de, Yeni tanımlama penceresi 6.2 de gösterilmektedir.

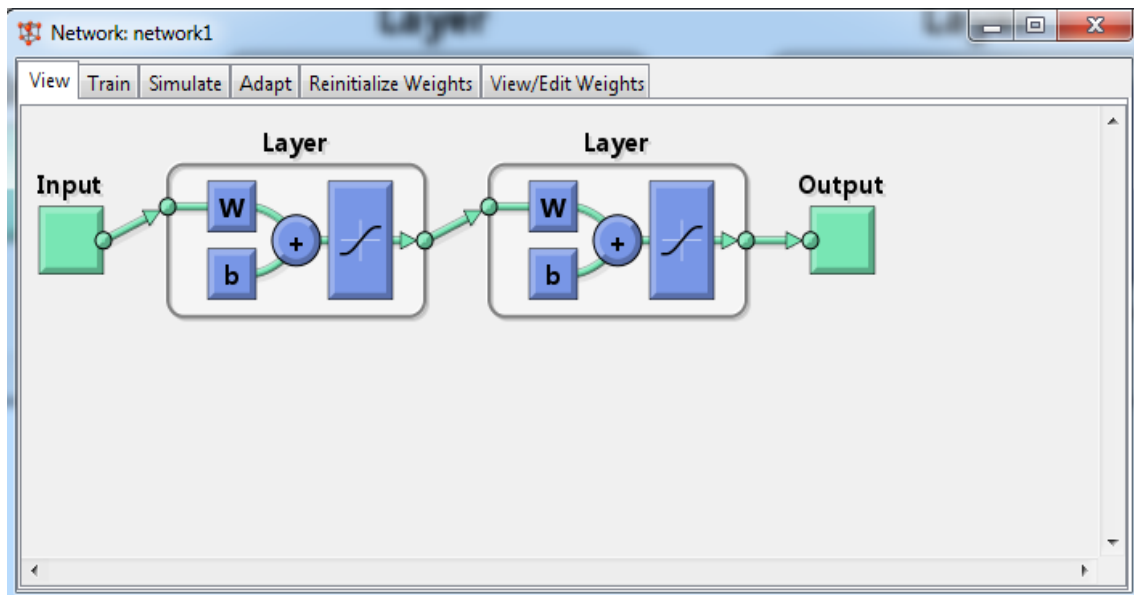


Şekil 6.1 Matlab Giriş Tanımlamaları



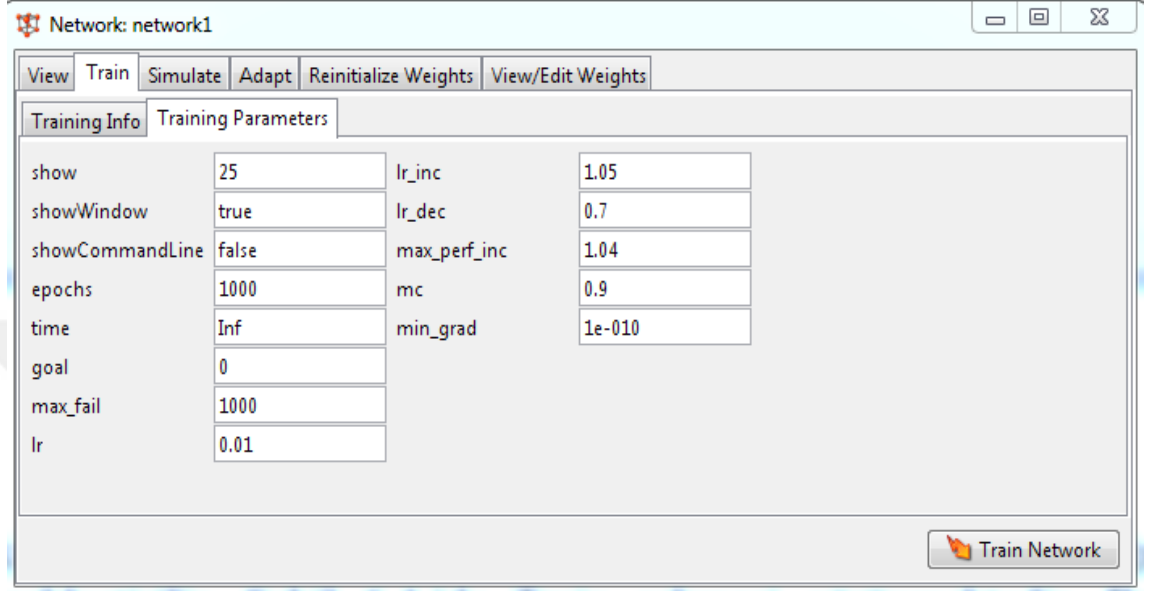
Şekil 6.2 Matlab Yeni Tanımlama pencresi

Şekil 6.3’de oluşturulan yapay sinir ağ modelinin görüntüsü yer almaktadır.



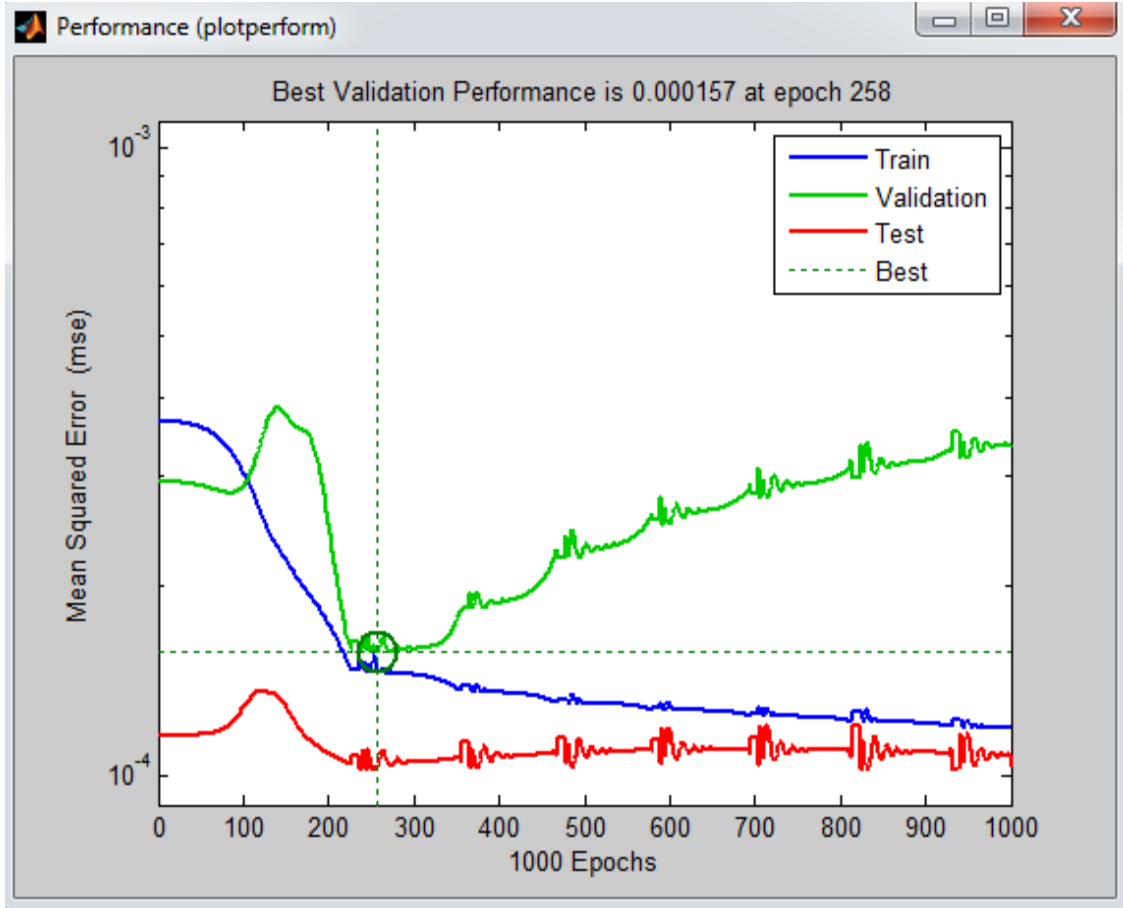
Şekil 6.3 Yapay Sinir Ağı Gösterimi

Şekil 6.3'daki matlab penceresinin "Train" sekmesinde ağı eğitimi işlemi gerçekleştirilir. Şekil 6.4.'de Train sekmesi görünmektedir. Burada momentum katsayısı, öğrenme katsayısı ve çevrim sayısı gibi öğrenme performansını etkileyen parametreler seçilir. Daha sonra "Train Network" butonuna basılarak ağı eğitilir.

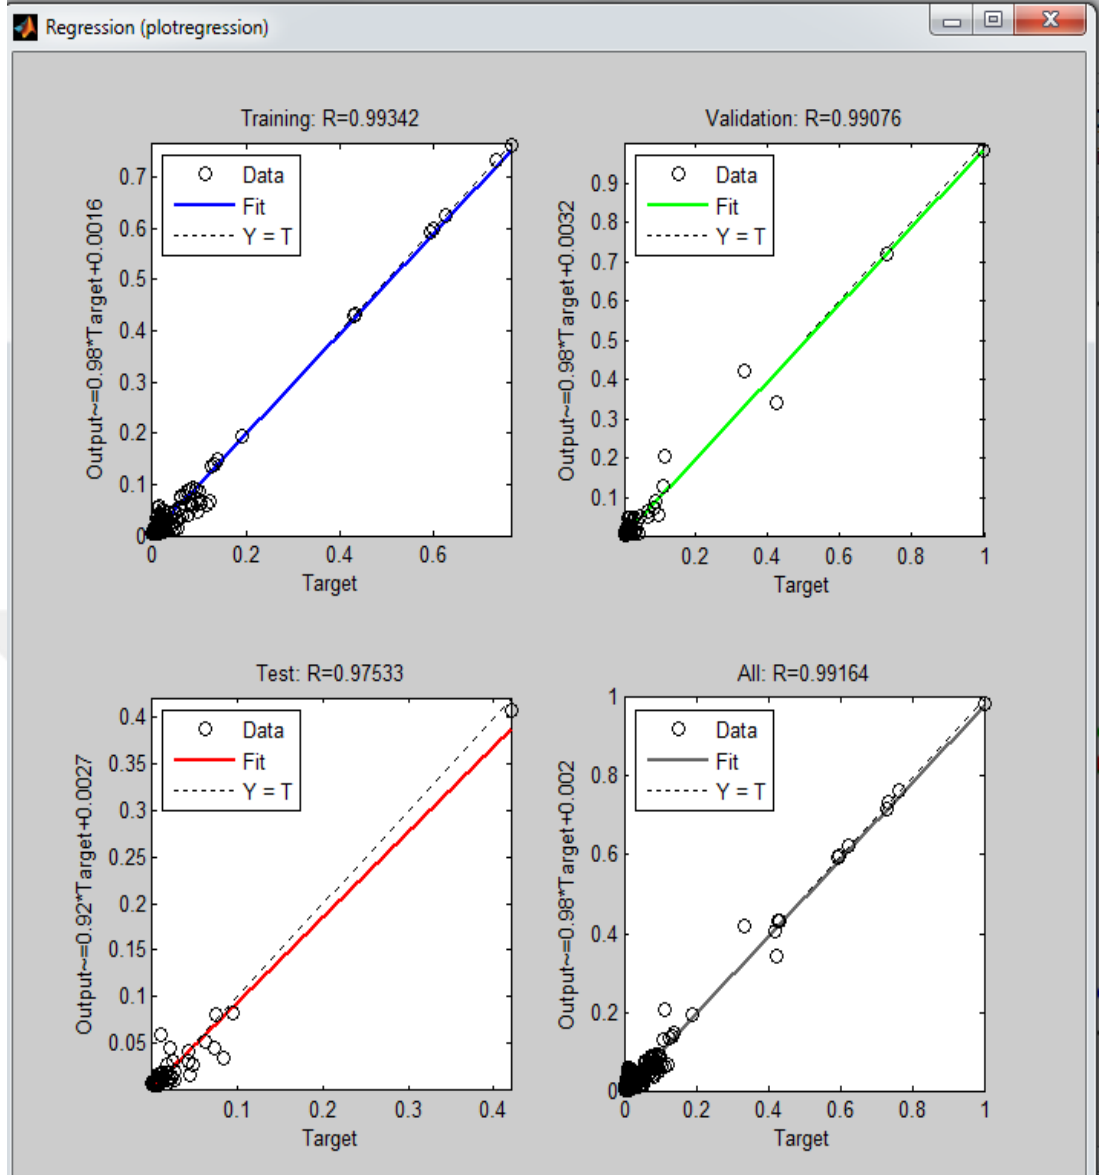


Şekil 6.4 Matlab'ta YSA eğitim ekranı

Eğitim sonucunda her iterasyondaki eğitim, doğrulama ve test kümelerine ilişkin hata değerlerinin ne şekilde değiştiğini gösteren grafik Şekil 6.5.'de yer almaktadır. Grafikte görüldüğü üzere ağı eğitimi 1000 iterasyonda optimum sonuca ulaşmıştır. Matlabta öğrenmeden sonra elde edilene regresyon grafiği Şekil 6.6.'de gösterilmektedir. Bu grafiğe göre en düşük değer 0.94798 olan test kümesine aittir. Buradan da anlaşılacağı üzere öğrenme işlemi büyük başarıyla gerçekleştirilmiştir. Bağımsız değişken olarak belirlediğimiz faktörler en az 0.94 oranında satış talebini etkilemektedir.



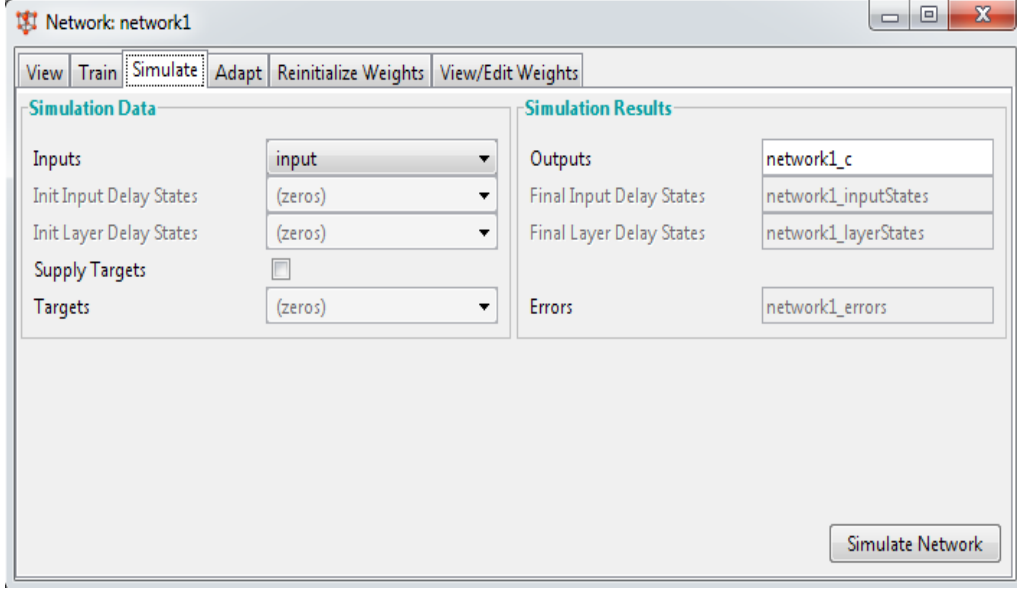
Şekil 6.5 Eğitim, doğrulama ve test kümelerine ilişkin hata performansları



Şekil 6.6 Matlab'ta öğrenme, doğrulama ve test kümelerine ilişkin regresyon grafiği

6.3 Sonuçların Test Edilmesi ve Değerlendirilmesi

Ağ eğitildikten sonra bu ekranda "Simulate" sekmesinden test girdi seti için ağı tahmini test verilerini üretmesi sağlanır. Şekil 6.7.'de "Simulate" penceresi yer almaktadır. Burada test girdi verisi seçilir ve "Simulate Network" butonuna basılarak ağı test edilmesi işlemi gerçekleştirilmektedir.



Şekil 6.7 Matlab'ta YSA test ekranı

Test işleminden sonra ağı tahmin olarak verdiği test çıktı verileri ile gerçek değerlerin karşılaştırılması gerekmektedir. Buna göre MSE değeri 0,28 olarak bulunmuştur. Aşağıdaki Çizelge 6.1.'de tahmini ve gerçek değerlerin toplam miktarları yer almaktadır. Test verilerinin toplam tutarı ile tahmin verilerinin toplam tutarı arasında %3,87 'lik bir sapma vardır. Çizelge 6.2.'de de gerçek değerler ile çıktı tahmin değerlerinin kıyaslanması yer almaktadır.

Çizelge 6.1. YSA'ya göre tahmin performansı

Tahmini Değer (Toplam)	Gerçek Değer (Toplam)	Toplam Sapma %
44.096.950	45.874.034	3,87%


Çizelge 6.2. YSA sonucu bulunan tahmini değerler ile gerçek değerlerin karşılaştırılması

TEST KÜMESİ			
GERÇEKLEŞEN (Normalize)	TAHMİN (Normalize)	TAHMİN	GERÇEKLEŞEN
0,0945588	0,094510	1.515.634	1.515.949
0,0222674	0,021703	348.046	356.498
0,0054188	0,000800	12.831	86.269
0,0070995	0,007786	124.862	113.225
0,0012170	0,001626	26.077	18.879
0,0008235	0,000962	15.421	12.567
0,5978259	0,600070	9.623.174	9.587.639
0,0653289	0,065551	1.051.225	1.047.142
0,0014239	0,000567	9.096	22.197
0,0009880	0,000579	9.278	15.206
0,0043876	0,005069	81.282	69.731
0,0092577	0,022886	367.017	147.840
0,0015278	0,000552	8.856	23.864
0,0114393	0,015461	247.944	182.830
0,0030800	0,000469	7.522	48.758
0,0017740	0,000562	9.015	27.813
0,0063198	0,002438	39.104	100.720
0,0030245	0,002891	46.359	47.868
0,0014050	0,000705	11.311	21.893
0,0005276	0,002582	41.405	7.821
0,0803924	0,056183	900.993	1.288.740
0,0026274	0,005678	91.061	41.500
0,0008100	0,000615	9.869	12.351
0,0018539	0,004610	73.928	29.093
0,0225463	0,023955	384.160	360.970
0,0424968	0,042831	686.870	680.948
0,0006499	0,000929	14.895	9.783
0,0031515	0,000759	12.177	49.904
0,0262156	0,027892	447.297	419.821
0,0053788	0,000651	10.436	85.628
0,0196419	0,009613	154.166	314.388
0,0083039	0,003463	55.529	132.542
0,0709078	0,071121	1.140.550	1.136.621
0,0025999	0,002867	45.974	41.059
0,0009492	0,000444	7.119	14.583

TEST KÜMESİ			
GERÇEKLEŞEN (Normalize)	TAHMİN (Normalize)	TAHMİN	GERÇEKLEŞEN
0,0004950	0,000821	13.165	7.299
0,0217038	0,008543	137.008	347.457
0,0014547	0,000536	8.592	22.691
0,0055403	0,000536	8.589	88.218
1,0000000	1,000000	16.036.753	16.037.941
0,1898593	0,189830	3.044.257	3.044.434
0,0196261	0,018538	297.289	314.135
0,0001259	0,000616	9.880	1.379
0,0014801	0,000653	10.464	23.098
0,0005379	0,000972	15.580	7.987
0,0003164	0,000978	15.688	4.433
0,0434134	0,041179	660.377	695.649
0,0005261	0,000856	13.724	7.798
0,0006337	0,000825	13.227	9.524
0,0005724	0,000540	8.656	8.541
0,0024267	0,000624	10.007	38.281
0,0082626	0,007830	125.568	131.879
0,0994908	0,099344	1.593.155	1.595.051
0,0049053	0,006445	103.362	78.033
0,0361697	0,035400	567.701	579.471
0,0143270	0,018008	288.790	229.144
0,0190175	0,012313	197.461	304.373
0,0199310	0,020146	323.076	319.025
0,0070515	0,003549	56.908	112.456
0,0080223	0,007950	127.497	128.026
0,0003702	0,001054	16.900	5.296
0,0012571	0,001125	18.037	19.522
0,0050819	0,002304	36.952	80.867
0,0097711	0,007291	116.929	156.075
0,0044573	0,002161	34.647	70.848
0,0107410	0,003093	49.597	171.631
0,0766715	0,076945	1.233.948	1.229.062
0,0055340	0,001264	20.277	88.116
0,0014969	0,000592	9.487	23.367
0,0092679	0,003608	57.864	148.004
0,0198427	0,019479	312.380	317.608
0,0027337	0,005627	90.244	43.205
0,0061198	0,005230	83.864	97.512
0,0090480	0,000558	8.956	144.477
0,0203560	0,019250	308.707	325.840

TEST KÜMESİ			
GERÇEKLEŞEN (Normalize)	TAHMİN (Normalize)	TAHMİN	GERÇEKLEŞEN
0,0018277	0,000542	8.694	28.674
0,0126521	0,010738	172.203	202.281
0,0187913	0,007089	113.685	300.745
0,0001140	0,000798	12.791	1.188
0,0060337	0,003832	61.448	96.131
0,0071867	0,000753	12.083	114.624

Şekil 6.8.'de test kümesi için ayırdığımız 81 adet verinin gerçek değerleri ile YSA ağının üretmiş olduğu tahmini değerlerin grafiksel gösterimini yer almaktadır. Grafikten de görüleceği üzere fiili değerler iyi bir şekilde tahmin edilmiştir.



Şekil 6.8. YSA ile bulunan tahmini değerler ile gerçek değerlerin grafik gösterimi



7. SONUÇ VE ÖNERİLER

Tahmin, gelecekte neyin nasıl olacağını önceden kestirilmesidir. Hemen hemen bütün yönetsel kararlar ileriye yönelik tahminlere dayanmaktadır. Bu yüzden tüm firmalar gelecekte karşılaşılabileceği belirsiz durumları önceden tahmin ederek, buna uygun önlemler ve iyileştirmeler yapmak durumundadırlar. Dolayısıyla uygulamasını yaptığımız işletme probleminin çözümünde bir tahmin aracı olarak yapay sinir ağlarına ait geri yayılım algoritması denenmiştir. YSA teorisi araştırılarak, tahmin üzerinde yapılmış olan uygulamalar incelenmiştir. Tahmin çalışmasının başarısını ölçebilmek için gerçek değerlerle YSA tahmin sonuçları ile karşılaştırılmıştır. YSA modeli aralarında lineer ilişki bulunmayan birçok değişkene bağlı problemin çözümünde olumlu sonuçlar vermektedir. Geleneksel istatistiksel analizler genelde göstergelerin normal dağılım gösterdiğini savunmaktadır.

Uygulama çalışmamızda, 2010-2015 yılları arasında gerçekleşen il bazlı satış verileri tutar cinsinden verilmiştir. Satışları etkileyen faktörler, çalışma öncesinde görüşülen uzman kişilerin görüşleri alınarak belirlenmiştir. Bu faktörlere ait bilgiler, TÜİK, IMKB vb. kurum kaynaklarından elde edilmiştir. Eğitim yayıncılığı firmalara yayın satışını etkileyen 7 ana faktör olduğunu düşünülmüştür. Bunlar; Satış Hacmi, Öğrenci sayısı, hane eğitim harcaması, dolar kuru, müşteri sayısı, Tüfe ve Üfe' dir. Bu bağımsız değişkenlerin yayıncılık satışını nasıl etkilediği yapılan çalışmalar sonucunda bulunmuştur. Ayrıca satışları etkileyen diğer 2 etken de o ay içinde M.E.B.'nin uyguladığı eğitim politikası ve Yerel yönetimlerin (Valilik, Kaymakamlık, Belediyeler, Kültür müdürlükleri vb.) yaptıkları kültürel faaliyetler , sınavlara hazırlık çalışmaları yayın satışlarını ve kullanımını ciddi oranda etkilemektedir. Eğitim Yayın sektörü bazı illerde öğrenci sayısı ve Hane alım gücü yüksek olduğu için satış tutarları diğer illere göre yüksek hesaplanmıştır. Bu yüzden bazı aylar için hesaplanan tahminlerin hataları çok fazladır. Bu veriler (0.1, 0.9) aralığında normalleştirilerek eğitim ve test amacıyla ağa sunulmuştur. 2015 yılında 81 adet veri ise ağın test edilmesi için kullanılmıştır. Yapılan çalışmalar sonucunda YSA tekniğinin başarılı olduğu görülmüş ve test verilerine ait değerler için tahmini değerler bulunmuştur. Bu değerler gerçek verilerle karşılaştırılmış ve gerçek

değerleri ne derece yaklaştığı hesaplanmıştır. (MSE Değeri: 0,28, Tahmin ve Gerçekleşen Satış tutarları arasındaki Sapma: 3,87) En düşük hata değerini veren yapay sinir ağları ile bulunan değerdir. İleriye yönelik yapılacak çalışmalar için, farklı mimariye sahip YSA modelleri kullanılarak tahminler önerilebilir. Yapay sinir ağları hem doğrusal hem de doğrusal olmayan ilişkileri modelleyebilmesine karşılık, her veri seti için aynı etkinlikte sonuçlar sağlayamamaktadır. Yapılan çalışmalar, tek bir yöntemle tahmin etmek yerine, verilerdeki farklı fonksiyonel ilişkileri modelleyebilen birden fazla yöntem birleştirilerek tahmin yapmanın daha iyi sonuçlar verdiğini göstermektedir. İleride yapılan çalışmalarda aynı veriler, farklı modeller ile denenecektir.



KAYNAKLAR

Akbay, Aysel Özdeş, Aktaş, Erkan ve Koç, Ali (1999). Konsantre Meyve Suyu Talebinin "Tobit" Modeli ile Analizi, Turkish Journal of Agriculture and Forestry, 23(1999): 493-499.

Aksoy, Hafzullah ve Dahamsheh, Ahmad (2009). Artificial neural network models for forecasting monthly precipitation in Jordan, Stock Environ Res Risk Assess (2009) 23: 917–931.

Asilkan, Özcan ve Irmak, Sezgin (2009). İkinci El Otomobillerin Gelecekteki Fiyatlarının Yapay Sinir Ağları ile Tahmin Edilmesi, Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 14(2) 2009: 375-391.

Avcı, Emin (2009). Yapay Sinir Ağları Modelleri İle Hisse Senedi Getiri Tahminleri, Marmara Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 26(1) 2009: 443-461.

Başaran S., "Yapay Sinir Ağları Kullanarak Konuşmacı Tanıma", Yüksek Lisans Tezi, T.C. Uludağ Üniversitesi Fen Bilimleri Ens. Elektronik Müh. Anabilim Dalı, Bursa, (2007).

Carlson, RL and Umble, M (1980). Statistical demand functions for automobiles and their use for forecasting in an energy crisis. The Journal of Business, 53,2-10.

Chen, Jui-Chi (2000). Forecasting Method Applications to Recreation and Tourism Demand, Doktora Tezi, North Carolina State University, USA.

Doğan G.(2010) "Yapay Sinir Ağları Kullanılarak Türkiye'deki Özel Bir Sigorta Şirketinde Portföy Değerlendirmesi", Yüksek Lisans Tezi, Hacettepe Üniv. İstatistik Anabilim Dalı, (2010)

Chung, Seunghyun (2001). Demand modeling and analysis for the management of underground infrastructure systems, Doktora Tezi, Purdue University, USA.

Cahow, Eric E. (2004). Forecast of demand for chronic care nursing home services: 2005-2025, Doktora Tezi, Brandeis University, Waltham Massachusetts, USA.

Elmas Ç., "Yapay Sinir Ağları (kuram, mimari, eğitim, uygulama", Seçkin Yayıncılık , (2003).

Eti S., "Finansal Verilere Karşılığı Açıklayan Mollerin Karşılaştırılması Üzerine Bir Araştırma", Yüksek Lisans Tezi , (2016).

Gavcar, Erdoğan, Şen, Selim ve AYTEKİN, Alper (1999). Türkiye’de Kullanılan KağıtKarton Türlerinin Talep Tahminlerinin Belirlenmesi. Tr. Journal of Agriculture and Forestry, TÜBİTAK, 23 (1999) 203-211.

Griffiths, William E., Newton, Lisa S. and O’Donnell, Christopher J. (2010). Predictive densities for models with stochastic regressors and inequality constraints: Forecasting local-area wheat yield, International Journal of Forecasting, 26 (2010) 397–412.

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

HAN J., KAMBER M., (2001), Data Mining Concepts And Technques, Second Edition, Morgan- Kaufmann Academic Press Elsevier Inc., ABD.

Hu, Clark (2002). Advanced Tourism Demand Forecasting: ANN and Box-Jenkins Modelling, Doktora Tezi, Purdue University, MI, USA.

Jones, Spencer S. (2008). Measuring, Modeling, and Forecasting Demand in The Emergency Department, Doktora Tezi, The University of Utah, USA.

Karaath, M. Yapay Sinir Ağları Yöntemi ile Tahmin (İMKB’ de Bir Uygulama), Süleyman Demirel Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Yüksek Lisans Tezi, 2003.

Karahanlı ,İstatistiksel Tahmin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmin Uygulaması, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, İşletme Anabilim Dalı, Doktora Tezi, 2011.

Kargı, V. 2015. Yapay Sinir Ağ Modelleri ve Bir Tekstil Firmasında Uygulama, 1.Cilt, Ekin Yayınevi, 1-163.

Kaya H ve Köymen K, 2008. Veri Madenciliği Kavramı ve Uygulama Alanları, Maltepe Üniversitesi, Bilgisayar Mühendisliği Bölümü, İstanbul

Khare M.,Nagendra S.M, "Artificial Neural Networks in Vehicular Pollution Modelling", Springer, (2007).

Kirby, Howard R., Watson, Susan M. and Dougherty, Mark S. (1997). Should we use neural networks or statistical models for short-term motorway traffic forecasting? International Journal of Forecasting, 13 (1997) 43-50.

Olgun, S. Tedarik Zinciri Yönetiminde Talep Tahmini Yöntemler ve Yapay Zeka Tabanlı Bir Talep Tahmini Modelinin Uygulanması, İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi, 2009.

Öztemel, Ercan (2006). Yapay Sinir Ağları (2. Baskı). İstanbul: Papatya Yayıncılık.

Özçalıcı, Hisse Senedi Fiyat Tahminlerinde Bilgi İşlemsel Zeka Yöntemler,

Kahramanmaraş Sütçü İmam Üniversitesi, Sosyal Bilimleri Enstitüsü, İşletme Mühendisliği Bölümü, Doktora Tezi, 2015

Rajpal, P.S., Shishodia, K.S. ve Sekhon, G.S. (2006). An artificial neural network for modeling reliability, availability and maintainability of a repairable system. Reliability Engineering and System Safety, 91 (2006), 809-819.

Rao, Ananda M ve Srinivas, J (2003). Neural Networks Algorithms and Applications. Pangbourne England: Alpha Science International Ltd.

Sarıoğlu Ş., Beşdok E., Erler M., Mühendislikte Yapay Zeka Uygulamaları Yapay Sinir Ağları, Ufuk Kitap Kırtasiye- Yayıncılık Tic. Ltd. Şti., (2003).

Satır, Benhür ve Köksal, Mustafa (2006). Entegre Tavuk Organizasyonları İçin Genel Üretim ve Finansal Planlama Modeli. <http://academic.cankaya.edu.tr/~benhur/cv/yaem2004.doc> Erişim Tarihi: 15.10.2010.

Saygılı, Yasin S. (2008). İstatistiksel Yöntemlerle Yapay Sinir Ağları Uygulamalarının Karşılaştırılması: Milli Savunma Bakanlığı Bütçesinin Öngörülmesi, Yüksek Lisans Tezi, Kara Harp Okulu Savunma Bilimleri Enstitüsü, Ankara.

Sönmez, (2013). Banka Karlılığını Esnek Hesaplama Teknikleri İle Ölçen Akıllı Yazılım Modeli Tasarımı, Doktora Tezi, Marmara Üniversitesi Bankacılık Ve Sigortacılık , Enstitüsü, İstanbul

Tekin, Mahmut (2008). Sayısal Yöntemler: Bilgisayar Çözümlü Alıştırmalar (Güncelleştirilmiş 6. Baskı). Konya: Günay Ofset.

Toktaş, İhsan ve Aktürk, Nizami (2004). Makine Tasarım İşleminde Kullanılan Yapay Zeka Teknikleri ve Uygulama Alanları, Makine Teknolojileri Elektronik Dergisi, 2004 (2) 7-20.

Wong, Bo K, Bodnovich, Thomas A, Selvi, Yakup (1997). Neural network applications in business: A review and analysis of the literature (1988-95), Decision Support Systems 19 (1997): 301-320.

Wong, Bo K, Bodnovich, Thomas A, Selvi, Yakup (1997). Neural network applications in business: A review and analysis of the literature (1988-95), Decision Support Systems 19 (1997): 301-320.

Yıldırım, Ankara'da Şehir İçinde Meydana Gelen Trafik Kazaların Analizi, Kritik Noktaların Belirlenmesi ve Bir Yapay Sinir Ağı İle Modellenmesi , Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Lisans Tezi, 2014.

Yazıcıoğlu, N. Yapay Zeka İle Talep Tahmini, Uludağ Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi, 2010.

Yu, Wen-Bin (2003). Agent-based demand forecasting for supply chain

management. Doktora Tezi, University of Louisville Kentucky, USA.

Yurdakul M., "Karbonat Kökenli Doğal Taşların Yapay Sinir Ağları ile Kesilebilirlik Tayini", Doktora Tezi, Osmangazi Üniversitesi Maden Mühendisliği Anabilim Dalı, Eskişehir, (2009).

Yücesoy, M. Temizlik Sektöründe Yapay Sinir Ağları ile Talep Tahmini, İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Bölümü, Yüksek Lisans Tezi, 2011.

Yüksek, Ahmet Gürken (2007). Hava Kirliliği Tahmini YSA Çoklu Regresyon, Doktora Tezi, Cumhuriyet Üniversitesi Sosyal Bilimler Enstitüsü, Sivas.

ZhoumcMahon, S.L, Walton, T.A and Lewis, A (2002). Forecasting operational demand for an urban water supply zone. Journal of Hydrology, 259(1): 189- 202.

INTERNET KAYNAKLARI

[1] **Pek M (2016)**, Yapay Sinir Ağları Nedir , İleri ve Geri Beslemeli ağları nelerdir, Alındığı Tarih : 18.08.2016, Adres: <http://mesutpek.com/yapay-sinir-aglari-nedir-ileri-ve-geri-beslemeli-aglari-nelerdir.html>

[2] **Akgul M (2015)**, Nedir bu veri madenciliği , Alındığı Tarih : 18.08.2016, Adres: <https://akgulmustafa.wordpress.com/2015/03/01/nedir-bu-veri-madenciligi/>

EKLER

EK A: Test İçin Kullanılan Veriler

İL	Yıl	Satış Hacmi	Öğrenci Sayıları	Hane Eğitim Harcama tutarı	Dolar Kuru	Tüfe	Üfe	Müşteri Sayısı
ADANA	2010	1.355.250	480.034	32.208.867	1,545	6,4	8,87	8
ADYAMAN	2010	151.448	152.170	2.647.391	1,545	6,4	8,87	4
AFYON	2010	97.065	136.920	7.234.428	1,545	6,4	8,87	13
AĞRI	2010	14.886	164.105	2.090.368	1,545	6,4	8,87	8
AKSARAY	2010	40.953	81.940	4.546.856	1,545	6,4	8,87	3
AMASYA	2010	43.642	64.586	5.435.026	1,545	6,4	8,87	5
ANKARA	2010	5.352.474	938.320	161.485.947	1,545	6,4	8,87	42
ANTALYA	2010	663.875	419.061	36.501.886	1,545	6,4	8,87	51
ARDAHAN	2010	4.795	21.726	603.950	1,545	6,4	8,87	1
ARTVİN	2010	18.278	28.843	2.024.111	1,545	6,4	8,87	4
AYDIN	2010	111.639	176.156	9.686.659	1,545	6,4	8,87	26
BALIKESİR	2010	165.917	185.622	16.458.819	1,545	6,4	8,87	16
BARTIN	2010	13.767	38.282	1.005.886	1,545	6,4	8,87	3
BATMAN	2010	106.838	166.733	2.079.543	1,545	6,4	8,87	5
BAYBURT	2010	20.079	15.792	223.253	1,545	6,4	8,87	3
BİLECİK	2010	48.726	36.147	2.005.065	1,545	6,4	8,87	7
BİNGÖL	2010	101.266	61.256	384.253	1,545	6,4	8,87	6
BİTLİS	2010	56.293	96.986	351.469	1,545	6,4	8,87	3
BOLU	2010	22.461	47.020	3.515.990	1,545	6,4	8,87	4
BURDUR	2010	55.446	43.777	2.541.051	1,545	6,4	8,87	10
BURSA	2010	1.145.487	486.875	36.304.995	1,545	6,4	8,87	16
ÇANAKKALE	2010	54.465	73.182	6.443.763	1,545	6,4	8,87	11
ÇANKIRI	2010	64.725	28.382	1.645.452	1,545	6,4	8,87	4
ÇORUM	2010	39.992	103.514	7.811.598	1,545	6,4	8,87	6
DENİZLİ	2010	184.583	180.181	10.506.110	1,545	6,4	8,87	14
DİYARBAKIR	2010	267.997	484.808	5.756.621	1,545	6,4	8,87	5
DÜZCE	2010	12.288	67.403	1.892.649	1,545	6,4	8,87	3
EDİRNE	2010	25.869	56.909	8.781.353	1,545	6,4	8,87	6
ELAZIĞ	2010	210.948	133.580	5.986.829	1,545	6,4	8,87	6
ERZİNCAN	2010	27.940	41.273	959.381	1,545	6,4	8,87	2
ERZURUM	2010	154.725	178.233	2.677.020	1,545	6,4	8,87	7

EK A: Test İçin Kullanılan Veriler (Devam)

İL	Yıl	Satış Hacmi	Öğrenci Sayıları	Hane Eğitim Harcama tutarı	Dolar Kuru	Tüfe	Üfe	Müşteri Sayısı
ESKİŞEHİR	2010	86.206	131.570	16.389.718	1,545	6,4	8,87	12
GAZİANTEP	2010	704.808	513.172	16.323.087	1,545	6,4	8,87	16
GİRESUN	2010	97.601	77.871	5.973.643	1,545	6,4	8,87	6
GÜMÜŞHANE	2010	10.314	21.565	1.171.162	1,545	6,4	8,87	1
HAKKARİ	2010	16.629	72.440	69.948	1,545	6,4	8,87	3
HATAY	2010	265.821	361.970	16.665.888	1,545	6,4	8,87	18
IĞDIR	2010	10.472	38.817	556.297	1,545	6,4	8,87	3
ISPARTA	2010	221.398	82.771	2.628.592	1,545	6,4	8,87	16
İSTANBUL	2010	9.492.705	2.496.245	371.459.911	1,545	6,4	8,87	205
İZMİR	2010	1.812.863	671.909	84.486.119	1,545	6,4	8,87	54
KAHRAMANMARAŞ	2010	265.007	277.081	12.205.302	1,545	6,4	8,87	9
KARABÜK	2010	32.858	37.842	745.269	1,545	6,4	8,87	6
KARAMAN	2010	67.797	48.777	830.520	1,545	6,4	8,87	3
KARS	2010	11.649	70.238	2.088.410	1,545	6,4	8,87	2
KASTAMONU	2010	51.687	57.763	4.483.375	1,545	6,4	8,87	6
KAYSERİ	2010	175.924	279.094	12.436.367	1,545	6,4	8,87	17
KIRIKKALE	2010	-640	53.164	1.545.765	1,545	6,4	8,87	2
KIRKLARELİ	2010	33.087	51.504	4.814.709	1,545	6,4	8,87	7
KIRŞEHİR	2010	10.903	25.944	2.667.313	1,545	6,4	8,87	3
KİLİS	2010	18.464	31.775	596.435	1,545	6,4	8,87	2
KOCAELİ	2010	180.173	332.098	17.285.118	1,545	6,4	8,87	23
KONYA	2010	1.537.348	470.559	29.720.681	1,545	6,4	8,87	37
KÜTAHYA	2010	59.225	98.654	5.200.790	1,545	6,4	8,87	12
MALATYA	2010	650.971	185.424	9.498.582	1,545	6,4	8,87	7
MANİSA	2010	199.398	248.764	12.876.013	1,545	6,4	8,87	31
MARDİN	2010	128.450	214.466	1.424.275	1,545	6,4	8,87	7
MERSİN	2010	188.332	365.370	23.413.768	1,545	6,4	8,87	8
MUĞLA	2010	59.326	146.069	8.295.465	1,545	6,4	8,87	8
MUŞ	2010	36.996	133.110	112.460	1,545	6,4	8,87	4
NEVŞEHİR	2010	16.861	56.499	2.946.988	1,545	6,4	8,87	5
NİĞDE	2010	7.514	73.454	3.061.965	1,545	6,4	8,87	3
ORDU	2010	87.560	132.061	4.879.078	1,545	6,4	8,87	9
OSMANİYE	2010	96.076	120.413	5.892.732	1,545	6,4	8,87	8
RİZE	2010	17.415	72.080	2.627.196	1,545	6,4	8,87	4
SAKARYA	2010	135.145	178.574	8.655.156	1,545	6,4	8,87	29
SAMSUN	2010	764.833	272.397	27.285.769	1,545	6,4	8,87	11
SİİRT	2010	68.103	95.374	596.455	1,545	6,4	8,87	4
SİNOP	2010	10.292	35.009	1.630.154	1,545	6,4	8,87	2

EK A: Test İçin Kullanılan Veriler (Devam)

İL	Yıl	Satış	Öğrenci	Hane Eğitim	Dolar	Tüfe	Üfe	Müşteri
		Hacmi	Sayıları	Harcama tutarı	Kuru			Sayısı
SİVAS	2010	121.756	123.799	3.898.459	1,545	6,4	8,87	13
ŞANLIURFA	2010	142.699	577.256	6.898.292	1,545	6,4	8,87	22
ŞIRNAK	2010	5.120	154.035	423.351	1,545	6,4	8,87	2
TEKİRDAĞ	2010	79.883	153.647	14.199.202	1,545	6,4	8,87	15
TOKAT	2010	104.507	115.909	5.533.372	1,545	6,4	8,87	12
TRABZON	2010	477.384	146.477	18.961.208	1,545	6,4	8,87	5
UŞAK	2010	54.214	60.475	3.667.525	1,545	6,4	8,87	6
VAN	2010	228.588	328.475	713.527	1,545	6,4	8,87	3
YALOVA	2010	11.804	38.754	1.212.381	1,545	6,4	8,87	1
YOZGAT	2010	84.671	93.654	1.280.401	1,545	6,4	8,87	13
ZONGULDAK	2010	129.437	107.873	3.984.010	1,545	6,4	8,87	13
ADANA	2011	1.609.981	480.034	33.904.106	1,87	10,45	13,33	9
ADIYAMAN	2011	170.497	152.170	2.786.730	1,87	10,45	13,33	4
AFYON	2011	131.243	136.920	7.615.196	1,87	10,45	13,33	13
AĞRI	2011	96.423	164.105	2.200.390	1,87	10,45	13,33	14
AKSARAY	2011	87.690	81.940	4.786.169	1,87	10,45	13,33	3
AMASYA	2011	44.566	64.586	5.721.086	1,87	10,45	13,33	5
ANKARA	2011	6.731.146	938.320	169.985.387	1,87	10,45	13,33	40
ANTALYA	2011	988.446	419.061	38.423.078	1,87	10,45	13,33	49
ARDAHAN	2011	13.930	21.726	635.738	1,87	10,45	13,33	2
ARTVİN	2011	19.499	28.843	2.130.646	1,87	10,45	13,33	4
AYDIN	2011	217.922	176.156	10.196.494	1,87	10,45	13,33	27
BALIKESİR	2011	165.260	185.622	17.325.091	1,87	10,45	13,33	16
BARTIN	2011	5.468	38.282	1.058.829	1,87	10,45	13,33	3
BATMAN	2011	112.794	166.733	2.188.995	1,87	10,45	13,33	4
BAYBURT	2011	44.657	15.792	235.003	1,87	10,45	13,33	4
BİLECİK	2011	61.929	36.147	2.110.597	1,87	10,45	13,33	8
BİNGÖL	2011	84.753	61.256	404.477	1,87	10,45	13,33	7
BİTLİS	2011	72.746	96.986	369.967	1,87	10,45	13,33	11
BOLU	2011	38.759	47.020	3.701.046	1,87	10,45	13,33	3
BURDUR	2011	71.347	43.777	2.674.793	1,87	10,45	13,33	11
BURSA	2011	1.373.790	486.875	38.215.824	1,87	10,45	13,33	16
ÇANAKKALE	2011	72.643	73.182	6.782.915	1,87	10,45	13,33	13
ÇANKIRI	2011	51.759	28.382	1.732.056	1,87	10,45	13,33	3
ÇORUM	2011	60.509	103.514	8.222.744	1,87	10,45	13,33	7
DENİZLİ	2011	226.427	180.181	11.059.075	1,87	10,45	13,33	10
DİYARBAKIR	2011	408.123	484.808	6.059.608	1,87	10,45	13,33	7
DÜZCE	2011	4.917	67.403	1.992.264	1,87	10,45	13,33	2

EK A: Test İçin Kullanılan Veriler (Devam)

İL	Yıl	Satış Hacmi	Öğrenci Sayıları	Hane Eğitim Harcama tutarı	Dolar Kuru	Tüfe	Üfe	Müşteri Sayısı
EDİRNE	2011	42.146	56.909	9.243.539	1,87	10,45	13,33	6
ELAZIĞ	2011	294.097	133.580	6.301.932	1,87	10,45	13,33	8
ERZİNCAN	2011	41.452	41.273	1.009.876	1,87	10,45	13,33	2
ERZURUM	2011	454.644	178.233	2.817.918	1,87	10,45	13,33	13
ESKİŞEHİR	2011	81.228	131.570	17.252.353	1,87	10,45	13,33	10
GAZİANTEP	2011	1.342.185	513.172	17.182.215	1,87	10,45	13,33	21
GİRESUN	2011	88.984	77.871	6.288.052	1,87	10,45	13,33	6
GÜMÜŞHANE	2011	18.901	21.565	1.232.803	1,87	10,45	13,33	2
HAKKARİ	2011	26.105	72.440	73.630	1,87	10,45	13,33	3
HATAY	2011	365.451	361.970	17.543.058	1,87	10,45	13,33	18
IĞDIR	2011	21.234	38.817	585.577	1,87	10,45	13,33	4
ISPARTA	2011	282.110	82.771	2.766.941	1,87	10,45	13,33	16
İSTANBUL	2011	11.747.503	2.496.245	391.010.844	1,87	10,45	13,33	243
İZMİR	2011	2.214.284	671.909	88.932.851	1,87	10,45	13,33	116
KAHRAMANMARAŞ	2011	345.603	277.081	12.847.700	1,87	10,45	13,33	11
KARABÜK	2011	34.420	37.842	784.495	1,87	10,45	13,33	6
KARAMAN	2011	103.192	48.777	874.232	1,87	10,45	13,33	4
KARS	2011	29.184	70.238	2.198.328	1,87	10,45	13,33	4
KASTAMONU	2011	34.987	57.763	4.719.347	1,87	10,45	13,33	5
KAYSERİ	2011	225.979	279.094	13.090.926	1,87	10,45	13,33	17
KIRIKKALE	2011	1.939	53.164	1.627.122	1,87	10,45	13,33	1
KIRKLARELİ	2011	17.620	51.504	5.068.121	1,87	10,45	13,33	3
KİRŞEHİR	2011	19.221	25.944	2.807.700	1,87	10,45	13,33	4
KİLİS	2011	18.997	31.775	627.827	1,87	10,45	13,33	2
KOCAELİ	2011	203.174	332.098	18.194.880	1,87	10,45	13,33	23
KONYA	2011	1.947.407	470.559	31.284.961	1,87	10,45	13,33	32
KÜTAHYA	2011	89.912	98.654	5.474.521	1,87	10,45	13,33	12
MALATYA	2011	697.646	185.424	9.998.518	1,87	10,45	13,33	10
MANİSA	2011	255.604	248.764	13.553.712	1,87	10,45	13,33	37
MARDİN	2011	208.133	214.466	1.499.238	1,87	10,45	13,33	10
MERSİN	2011	384.382	365.370	24.646.097	1,87	10,45	13,33	11
MUĞLA	2011	98.294	146.069	8.732.078	1,87	10,45	13,33	16
MUŞ	2011	61.866	133.110	118.379	1,87	10,45	13,33	9
NEVŞEHİR	2011	10.908	56.499	3.102.095	1,87	10,45	13,33	3
NİĞDE	2011	4.380	73.454	3.223.124	1,87	10,45	13,33	2
ORDU	2011	98.109	132.061	5.135.877	1,87	10,45	13,33	10
OSMANİYE	2011	133.087	120.413	6.202.882	1,87	10,45	13,33	7
RİZE	2011	50.145	72.080	2.765.473	1,87	10,45	13,33	5

EK A: Test İçin Kullanılan Veriler (Devam)

İL	Yıl	Satış	Öğrenci	Hane Eğitim	Dolar	Tüfe	Üfe	Müşteri
		Hacmi	Sayıları	Harcama tutarı	Kuru			Sayısı
SAKARYA	2011	211.235	178.574	9.110.700	1,87	10,45	13,33	21
SAMSUN	2011	1.034.041	272.397	28.721.892	1,87	10,45	13,33	13
SIİRT	2011	69.333	95.374	627.848	1,87	10,45	13,33	3
SİNOP	2011	19.595	35.009	1.715.953	1,87	10,45	13,33	2
SİVAS	2011	156.042	123.799	4.103.646	1,87	10,45	13,33	13
ŞANLIURFA	2011	178.245	577.256	7.261.368	1,87	10,45	13,33	27
ŞIRNAK	2011	25.342	154.035	445.633	1,87	10,45	13,33	3
TEKİRDAĞ	2011	69.682	153.647	14.946.544	1,87	10,45	13,33	13
TOKAT	2011	109.808	115.909	5.824.609	1,87	10,45	13,33	12
TRABZON	2011	551.484	146.477	19.959.188	1,87	10,45	13,33	9
TUNCELİ	2011	23.590	11.595	179.405	1,87	10,45	13,33	1
UŞAK	2011	117.840	60.475	3.860.556	1,87	10,45	13,33	7
VAN	2011	220.167	328.475	751.082	1,87	10,45	13,33	3
YALOVA	2011	7.732	38.754	1.276.192	1,87	10,45	13,33	1
YOZGAT	2011	87.329	93.654	1.347.792	1,87	10,45	13,33	12
ZONGULDAK	2011	165.202	107.873	4.193.699	1,87	10,45	13,33	11
ADANA	2012	1.514.073	492.876	35.743.209	1,7877	6,16	2,45	11
ADIYAMAN	2012	239.619	156.241	2.937.894	1,7877	6,16	2,45	4
AFYON	2012	121.061	140.583	8.028.276	1,7877	6,16	2,45	15
AĞRI	2012	102.804	168.495	2.319.748	1,7877	6,16	2,45	18
AKSARAY	2012	103.130	84.132	5.045.791	1,7877	6,16	2,45	4
AMASYA	2012	23.160	66.314	6.031.422	1,7877	6,16	2,45	7
ANKARA	2012	6.920.517	963.420	179.206.115	1,7877	6,16	2,45	44
ANTALYA	2012	1.061.089	430.271	40.507.309	1,7877	6,16	2,45	49
ARDAHAN	2012	13.260	22.307	670.223	1,7877	6,16	2,45	3
ARTVİN	2012	16.801	29.615	2.246.221	1,7877	6,16	2,45	4
AYDIN	2012	198.370	180.868	10.749.595	1,7877	6,16	2,45	27
BALIKESİR	2012	183.950	190.587	18.264.877	1,7877	6,16	2,45	23
BARTIN	2012	10.366	39.306	1.116.264	1,7877	6,16	2,45	3
BATMAN	2012	122.942	171.194	2.307.735	1,7877	6,16	2,45	4
BAYBURT	2012	28.290	16.215	247.751	1,7877	6,16	2,45	3
BİLECİK	2012	52.889	37.114	2.225.085	1,7877	6,16	2,45	6
BİNGÖL	2012	101.433	62.895	426.418	1,7877	6,16	2,45	9
BİTLİS	2012	82.963	99.581	390.036	1,7877	6,16	2,45	7
BOLU	2012	48.634	48.278	3.901.806	1,7877	6,16	2,45	6
BURDUR	2012	48.921	44.948	2.819.885	1,7877	6,16	2,45	12
BURSA	2012	1.159.880	499.899	40.288.812	1,7877	6,16	2,45	18
ÇANAKKALE	2012	76.075	75.139	7.150.849	1,7877	6,16	2,45	10

EK A: Test İçin Kullanılan Veriler (Devam)

İL	Yıl	Satış	Öğrenci	Hane Eğitim	Dolar	Tüfe	Üfe	Müşteri
		Hacmi	Sayıları	Harcama tutarı	Kuru			Sayısı
ÇANKIRI	2012	39.271	29.142	1.826.010	1,7877	6,16	2,45	3
ÇORUM	2012	59.917	106.283	8.668.780	1,7877	6,16	2,45	11
DENİZLİ	2012	245.432	185.001	11.658.966	1,7877	6,16	2,45	12
DİYARBAKIR	2012	623.790	497.777	6.388.306	1,7877	6,16	2,45	9
DÜZCE	2012	21.021	69.206	2.100.333	1,7877	6,16	2,45	3
EDİRNE	2012	22.080	58.431	9.744.948	1,7877	6,16	2,45	6
ELAZIĞ	2012	322.277	137.154	6.643.775	1,7877	6,16	2,45	10
ERZİNCAN	2012	57.502	42.377	1.064.655	1,7877	6,16	2,45	3
ERZURUM	2012	385.068	183.001	2.970.774	1,7877	6,16	2,45	14
ESKİŞEHİR	2012	79.152	135.090	18.188.194	1,7877	6,16	2,45	11
GAZİANTEP	2012	1.507.787	526.899	18.114.251	1,7877	6,16	2,45	20
GİRESUN	2012	77.709	79.954	6.629.143	1,7877	6,16	2,45	11
GÜMÜŞHANE	2012	13.354	22.142	1.299.676	1,7877	6,16	2,45	3
HAKKARİ	2012	32.789	74.377	77.624	1,7877	6,16	2,45	4
HATAY	2012	450.825	371.653	18.494.668	1,7877	6,16	2,45	23
İĞDIR	2012	32.980	39.855	617.341	1,7877	6,16	2,45	4
ISPARTA	2012	217.575	84.985	2.917.032	1,7877	6,16	2,45	18
İSTANBUL	2012	11.707.864	2.563.020	412.220.930	1,7877	6,16	2,45	253
İZMİR	2012	2.129.697	689.883	93.756.945	1,7877	6,16	2,45	105
KAHRAMANMARAŞ	2012	417.905	284.493	13.544.614	1,7877	6,16	2,45	12
KARABÜK	2012	14.088	38.854	827.049	1,7877	6,16	2,45	2
KARAMAN	2012	69.855	50.082	921.654	1,7877	6,16	2,45	5
KARS	2012	30.332	72.117	2.317.575	1,7877	6,16	2,45	6
KASTAMONU	2012	36.022	59.308	4.975.345	1,7877	6,16	2,45	4
KAYSERİ	2012	257.719	286.560	13.801.034	1,7877	6,16	2,45	16
KIRIKKALE	2012	5.421	54.586	1.715.384	1,7877	6,16	2,45	2
KIRKLARELİ	2012	21.798	52.882	5.343.037	1,7877	6,16	2,45	3
KIRŞEHİR	2012	17.462	26.638	2.960.002	1,7877	6,16	2,45	5
KİLİS	2012	19.306	32.625	661.883	1,7877	6,16	2,45	2
KOCAELİ	2012	203.539	340.982	19.181.847	1,7877	6,16	2,45	26
KONYA	2012	1.831.483	483.147	32.981.990	1,7877	6,16	2,45	34
KÜTAHYA	2012	72.685	101.293	5.771.483	1,7877	6,16	2,45	12
MALATYA	2012	760.823	190.384	10.540.880	1,7877	6,16	2,45	7
MANİSA	2012	238.324	255.419	14.288.923	1,7877	6,16	2,45	33
MARDİN	2012	249.395	220.203	1.580.563	1,7877	6,16	2,45	11
MERSİN	2012	418.334	375.143	25.983.006	1,7877	6,16	2,45	13
MUĞLA	2012	121.911	149.976	9.205.742	1,7877	6,16	2,45	20
MUŞ	2012	78.869	136.670	124.801	1,7877	6,16	2,45	13

EK A: Test İçin Kullanılan Veriler (Devam)

İL	Yıl	Satış	Öğrenci	Hane Eğitim	Dolar	Tüfe	Üfe	Müşteri
		Hacmi	Sayıları	Harcama tutarı	Kuru			Sayısı
NEVŞEHİR	2012	2.370	58.011	3.270.366	1,7877	6,16	2,45	2
NİĞDE	2012	31.776	75.419	3.397.960	1,7877	6,16	2,45	5
ORDU	2012	103.577	135.594	5.414.468	1,7877	6,16	2,45	11
OSMANİYE	2012	137.079	123.634	6.539.352	1,7877	6,16	2,45	5
RİZE	2012	34.329	74.009	2.915.483	1,7877	6,16	2,45	8
SAKARYA	2012	244.351	183.350	9.604.903	1,7877	6,16	2,45	21
SAMSUN	2012	1.334.576	279.684	30.279.889	1,7877	6,16	2,45	13
SİİRT	2012	59.607	97.926	661.905	1,7877	6,16	2,45	4
SİNOP	2012	36.323	35.945	1.809.034	1,7877	6,16	2,45	4
SİVAS	2012	138.684	127.110	4.326.245	1,7877	6,16	2,45	11
ŞANLIURFA	2012	155.416	592.697	7.655.256	1,7877	6,16	2,45	27
ŞIRNAK	2012	20.826	158.155	469.807	1,7877	6,16	2,45	4
TEKİRDAĞ	2012	82.960	157.757	15.757.308	1,7877	6,16	2,45	14
TOKAT	2012	120.161	119.009	6.140.560	1,7877	6,16	2,45	13
TRABZON	2012	587.582	150.395	21.041.859	1,7877	6,16	2,45	13
TUNCELİ	2012	23.562	11.905	189.137	1,7877	6,16	2,45	2
UŞAK	2012	95.777	62.093	4.069.969	1,7877	6,16	2,45	6
VAN	2012	277.091	337.262	791.824	1,7877	6,16	2,45	5
YALOVA	2012	10.039	39.791	1.345.418	1,7877	6,16	2,45	1
YOZGAT	2012	109.333	96.159	1.420.902	1,7877	6,16	2,45	10
ZONGULDAK	2012	169.420	110.759	4.421.183	1,7877	6,16	2,45	13
ADANA	2013	1.207.259	502.545	37.681.428	2,0667	7,4	6,97	10
ADIYAMAN	2013	192.883	159.306	3.097.205	2,0667	7,4	6,97	7
AFYON	2013	105.341	143.341	8.463.619	2,0667	7,4	6,97	13
AĞRI	2013	86.188	171.801	2.445.540	2,0667	7,4	6,97	16
AKSARAY	2013	98.880	85.782	5.319.405	2,0667	7,4	6,97	4
AMASYA	2013	21.392	67.615	6.358.484	2,0667	7,4	6,97	5
ANKARA	2013	6.881.218	982.321	188.923.788	2,0667	7,4	6,97	41
ANTALYA	2013	1.156.225	438.713	42.703.868	2,0667	7,4	6,97	46
ARDAHAN	2013	16.608	22.745	706.566	2,0667	7,4	6,97	2
ARTVİN	2013	21.734	30.196	2.368.025	2,0667	7,4	6,97	3
AYDIN	2013	136.350	184.417	11.332.505	2,0667	7,4	6,97	23
BALIKESİR	2013	204.336	194.326	19.255.312	2,0667	7,4	6,97	20
BARTIN	2013	10.233	40.077	1.176.795	2,0667	7,4	6,97	3
BATMAN	2013	131.034	174.552	2.432.875	2,0667	7,4	6,97	5
BAYBURT	2013	29.985	16.533	261.185	2,0667	7,4	6,97	3
BİLECİK	2013	23.444	37.842	2.345.743	2,0667	7,4	6,97	6
BİNGÖL	2013	119.714	64.129	449.541	2,0667	7,4	6,97	7

EK A: Test İçin Kullanılan Veriler (Devam)

İL	Yıl	Satış	Öğrenci	Hane Eğitim	Dolar	Tüfe	Üfe	Müşteri
		Hacmi	Sayıları	Harcama tutarı	Kuru			Sayısı
BİTLİS	2013	57.930	101.534	411.186	2,0667	7,4	6,97	11
BOLU	2013	20.035	49.225	4.113.387	2,0667	7,4	6,97	4
BURDUR	2013	63.923	45.830	2.972.797	2,0667	7,4	6,97	11
BURSA	2013	1.371.582	509.707	42.473.523	2,0667	7,4	6,97	25
ÇANAKKALE	2013	65.138	76.613	7.538.613	2,0667	7,4	6,97	12
ÇANKIRI	2013	36.331	29.713	1.925.028	2,0667	7,4	6,97	4
ÇORUM	2013	65.024	108.368	9.138.856	2,0667	7,4	6,97	8
DENİZLİ	2013	288.082	188.630	12.291.188	2,0667	7,4	6,97	15
DİYARBAKIR	2013	741.318	507.543	6.734.720	2,0667	7,4	6,97	12
DÜZCE	2013	14.101	70.564	2.214.226	2,0667	7,4	6,97	2
EDİRNE	2013	33.220	59.577	10.273.380	2,0667	7,4	6,97	9
ELAZIĞ	2013	272.463	139.845	7.004.042	2,0667	7,4	6,97	8
ERZİNCAN	2013	54.438	43.208	1.122.388	2,0667	7,4	6,97	3
ERZURUM	2013	455.894	186.591	3.131.868	2,0667	7,4	6,97	13
ESKİŞEHİR	2013	103.927	137.740	19.174.471	2,0667	7,4	6,97	14
GAZİANTEP	2013	1.290.749	537.236	19.096.518	2,0667	7,4	6,97	18
GİRESUN	2013	68.610	81.523	6.988.616	2,0667	7,4	6,97	10
GÜMÜŞHANE	2013	34.151	22.577	1.370.152	2,0667	7,4	6,97	7
HAKKARİ	2013	18.366	75.837	81.833	2,0667	7,4	6,97	4
HATAY	2013	403.499	378.945	19.497.564	2,0667	7,4	6,97	20
İĞDIR	2013	43.155	40.637	650.817	2,0667	7,4	6,97	3
ISPARTA	2013	183.836	86.652	3.075.212	2,0667	7,4	6,97	16
İSTANBUL	2013	12.242.149	2.613.304	434.574.119	2,0667	7,4	6,97	247
İZMİR	2013	2.031.700	703.418	98.841.032	2,0667	7,4	6,97	107
KAHRAMANMARAŞ	2013	409.885	290.074	14.279.087	2,0667	7,4	6,97	13
KARABÜK	2013	6.839	39.617	871.897	2,0667	7,4	6,97	2
KARAMAN	2013	75.866	51.064	971.632	2,0667	7,4	6,97	3
KARS	2013	29.784	73.532	2.443.248	2,0667	7,4	6,97	6
KASTAMONU	2013	33.380	60.472	5.245.139	2,0667	7,4	6,97	4
KAYSERİ	2013	273.834	292.182	14.549.412	2,0667	7,4	6,97	21
KIRIKKALE	2013	6.493	55.657	1.808.403	2,0667	7,4	6,97	2
KIRKLARELİ	2013	15.055	53.919	5.632.770	2,0667	7,4	6,97	5
KIRŞEHİR	2013	5.498	27.161	3.120.512	2,0667	7,4	6,97	4
KİLİS	2013	13.347	33.265	697.774	2,0667	7,4	6,97	2
KOCAELİ	2013	269.211	347.672	20.222.007	2,0667	7,4	6,97	28
KONYA	2013	1.659.676	492.625	34.770.479	2,0667	7,4	6,97	35
KÜTAHYA	2013	77.455	103.280	6.084.448	2,0667	7,4	6,97	14
MALATYA	2013	856.028	194.119	11.112.472	2,0667	7,4	6,97	7

EK A: Test İçin Kullanılan Veriler (Devam)

İL	Yıl	Satış	Öğrenci	Hane Eğitim	Dolar	Tüfe	Üfe	Müşteri
		Hacmi	Sayıları	Harcama tutarı	Kuru			Sayısı
MANİSA	2013	217.139	260.430	15.063.757	2,0667	7,4	6,97	35
MARDİN	2013	279.115	224.523	1.666.271	2,0667	7,4	6,97	12
MERSİN	2013	422.909	382.503	27.391.967	2,0667	7,4	6,97	12
MUĞLA	2013	143.104	152.918	9.704.935	2,0667	7,4	6,97	17
MUŞ	2013	74.919	139.352	131.568	2,0667	7,4	6,97	10
NEVŞEHİR	2013	666	59.149	3.447.706	2,0667	7,4	6,97	1
NİĞDE	2013	47.555	76.898	3.582.219	2,0667	7,4	6,97	6
ORDU	2013	99.613	138.254	5.708.075	2,0667	7,4	6,97	14
OSMANİYE	2013	124.315	126.060	6.893.957	2,0667	7,4	6,97	9
RİZE	2013	78.671	75.461	3.073.579	2,0667	7,4	6,97	6
SAKARYA	2013	159.508	186.948	10.125.741	2,0667	7,4	6,97	23
SAMSUN	2013	918.927	285.171	31.921.854	2,0667	7,4	6,97	14
SİİRT	2013	61.295	99.847	697.797	2,0667	7,4	6,97	4
SİNOP	2013	24.332	36.650	1.907.131	2,0667	7,4	6,97	4
SİVAS	2013	132.319	129.604	4.560.841	2,0667	7,4	6,97	12
ŞANLIURFA	2013	240.769	604.326	8.070.371	2,0667	7,4	6,97	26
ŞIRNAK	2013	37.822	161.258	495.282	2,0667	7,4	6,97	5
TEKİRDAĞ	2013	62.279	160.852	16.611.767	2,0667	7,4	6,97	9
TOKAT	2013	134.379	121.344	6.473.540	2,0667	7,4	6,97	10
TRABZON	2013	505.916	153.346	22.182.880	2,0667	7,4	6,97	16
TUNCELİ	2013	13.850	12.138	199.393	2,0667	7,4	6,97	1
UŞAK	2013	111.520	63.311	4.290.668	2,0667	7,4	6,97	8
VAN	2013	364.549	343.879	834.761	2,0667	7,4	6,97	7
YALOVA	2013	8.507	40.572	1.418.375	2,0667	7,4	6,97	2
YOZGAT	2013	113.665	98.045	1.497.952	2,0667	7,4	6,97	12
ZONGULDAK	2013	100.127	112.932	4.660.927	2,0667	7,4	6,97	13
ADANA	2014	948.330	500.405	40.092.853	2,2969	8,17	6,36	12
ADIYAMAN	2014	280.701	158.628	3.295.411	2,2969	8,17	6,36	7
AFYON	2014	80.737	142.730	9.005.249	2,2969	8,17	6,36	15
AĞRI	2014	70.773	171.069	2.602.042	2,2969	8,17	6,36	15
AKSARAY	2014	71.707	85.417	5.659.821	2,2969	8,17	6,36	4
AMASYA	2014	19.064	67.327	6.765.395	2,2969	8,17	6,36	6
ANKARA	2014	6.786.656	978.137	201.013.974	2,2969	8,17	6,36	47
ANTALYA	2014	760.681	436.844	45.436.704	2,2969	8,17	6,36	46
ARDAHAN	2014	10.619	22.648	751.783	2,2969	8,17	6,36	2
ARTVİN	2014	16.702	30.067	2.519.567	2,2969	8,17	6,36	3
AYDIN	2014	62.771	183.631	12.057.729	2,2969	8,17	6,36	21
BALIKESİR	2014	109.597	193.499	20.487.557	2,2969	8,17	6,36	23

EK A: Test İçin Kullanılan Veriler (Devam)

İL	Yıl	Satış	Öğrenci	Hane Eğitim	Dolar	Tüfe	Üfe	Müşteri
		Hacmi	Sayıları	Harcama tutarı	Kuru			Sayısı
BARTIN	2014	8.227	39.906	1.252.104	2,2969	8,17	6,36	3
BATMAN	2014	92.242	173.809	2.588.567	2,2969	8,17	6,36	5
BAYBURT	2014	29.953	16.463	277.900	2,2969	8,17	6,36	4
BİLECİK	2014	35.123	37.681	2.495.859	2,2969	8,17	6,36	5
BİNGÖL	2014	81.210	63.856	478.309	2,2969	8,17	6,36	9
BİTLİS	2014	35.968	101.102	437.500	2,2969	8,17	6,36	9
BOLU	2014	15.797	49.015	4.376.623	2,2969	8,17	6,36	5
BURDUR	2014	21.890	45.635	3.163.041	2,2969	8,17	6,36	9
BURSA	2014	967.591	507.536	45.191.618	2,2969	8,17	6,36	24
ÇANAKKALE	2014	41.437	76.287	8.021.047	2,2969	8,17	6,36	7
ÇANKIRI	2014	12.474	29.587	2.048.220	2,2969	8,17	6,36	3
ÇORUM	2014	34.274	107.906	9.723.697	2,2969	8,17	6,36	9
DENİZLİ	2014	253.869	187.827	13.077.763	2,2969	8,17	6,36	15
DİYARBAKIR	2014	601.484	505.381	7.165.709	2,2969	8,17	6,36	10
DÜZCE	2014	8.769	70.263	2.355.926	2,2969	8,17	6,36	4
EDİRNE	2014	32.006	59.324	10.930.825	2,2969	8,17	6,36	7
ELAZIĞ	2014	262.217	139.249	7.452.266	2,2969	8,17	6,36	9
ERZİNCAN	2014	49.158	43.024	1.194.215	2,2969	8,17	6,36	4
ERZURUM	2014	310.388	185.796	3.332.292	2,2969	8,17	6,36	17
ESKİŞEHİR	2014	92.751	137.153	20.401.542	2,2969	8,17	6,36	10
GAZİANTEP	2014	918.176	534.948	20.318.601	2,2969	8,17	6,36	15
GİRESUN	2014	53.217	81.175	7.435.853	2,2969	8,17	6,36	11
GÜMÜŞHANE	2014	27.947	22.480	1.457.835	2,2969	8,17	6,36	7
HAKKARİ	2014	11.829	75.514	87.070	2,2969	8,17	6,36	5
HATAY	2014	337.473	377.331	20.745.312	2,2969	8,17	6,36	20
İĞDIR	2014	27.537	40.464	692.466	2,2969	8,17	6,36	7
ISPARTA	2014	98.356	86.283	3.272.010	2,2969	8,17	6,36	14
İSTANBUL	2014	10.008.884	2.602.173	462.384.710	2,2969	8,17	6,36	214
İZMİR	2014	1.742.919	700.422	105.166.368	2,2969	8,17	6,36	87
KAHRAMANMARAŞ	2014	267.213	288.839	15.192.878	2,2969	8,17	6,36	12
KARABÜK	2014	1.756	39.448	927.694	2,2969	8,17	6,36	1
KARAMAN	2014	57.892	50.847	1.033.812	2,2969	8,17	6,36	4
KARS	2014	17.270	73.219	2.599.604	2,2969	8,17	6,36	5
KASTAMONU	2014	12.432	60.214	5.580.802	2,2969	8,17	6,36	5
KAYSERİ	2014	385.531	290.938	15.480.502	2,2969	8,17	6,36	22
KIRIKKALE	2014	1.946	55.420	1.924.132	2,2969	8,17	6,36	2
KIRKLARELİ	2014	8.668	53.689	5.993.239	2,2969	8,17	6,36	4
KIRŞEHİR	2014	4.330	27.045	3.320.209	2,2969	8,17	6,36	5

EK A: Test İçin Kullanılan Veriler (Devam)

İL	Yıl	Satış	Öğrenci	Hane Eğitim	Dolar	Tüfe	Üfe	Müşteri
		Hacmi	Sayıları	Harcama tutarı	Kuru			Sayısı
KİLİS	2014	29.744	33.123	742.428	2,2969	8,17	6,36	3
KOCAELİ	2014	214.598	346.191	21.516.115	2,2969	8,17	6,36	23
KONYA	2014	1.368.989	490.527	36.995.617	2,2969	8,17	6,36	28
KÜTAHYA	2014	65.604	102.840	6.473.823	2,2969	8,17	6,36	9
MALATYA	2014	487.397	193.292	11.823.615	2,2969	8,17	6,36	10
MANİSA	2014	187.672	259.320	16.027.763	2,2969	8,17	6,36	31
MARDİN	2014	258.142	223.567	1.772.904	2,2969	8,17	6,36	13
MERSİN	2014	179.801	380.874	29.144.917	2,2969	8,17	6,36	13
MUĞLA	2014	86.821	152.267	10.326.003	2,2969	8,17	6,36	21
MUŞ	2014	56.993	138.758	139.988	2,2969	8,17	6,36	11
NEVŞEHİR	2014	1.662	58.897	3.668.342	2,2969	8,17	6,36	2
NİĞDE	2014	17.848	76.571	3.811.463	2,2969	8,17	6,36	6
ORDU	2014	49.948	137.665	6.073.363	2,2969	8,17	6,36	11
OSMANİYE	2014	131.168	125.523	7.335.136	2,2969	8,17	6,36	8
RİZE	2014	49.765	75.139	3.270.273	2,2969	8,17	6,36	7
SAKARYA	2014	107.295	186.151	10.773.738	2,2969	8,17	6,36	19
SAMSUN	2014	834.297	283.957	33.964.694	2,2969	8,17	6,36	16
SİİRT	2014	64.048	99.421	742.453	2,2969	8,17	6,36	4
SİNOP	2014	27.056	36.494	2.029.178	2,2969	8,17	6,36	5
SİVAS	2014	110.476	129.052	4.852.712	2,2969	8,17	6,36	11
ŞANLIURFA	2014	220.667	601.752	8.586.835	2,2969	8,17	6,36	25
ŞIRNAK	2014	19.669	160.571	526.978	2,2969	8,17	6,36	4
TEKİRDAĞ	2014	49.464	160.167	17.674.838	2,2969	8,17	6,36	9
TOKAT	2014	119.193	120.827	6.887.814	2,2969	8,17	6,36	13
TRABZON	2014	358.916	152.692	23.602.474	2,2969	8,17	6,36	19
TUNCELİ	2014	16.847	12.087	212.153	2,2969	8,17	6,36	1
UŞAK	2014	122.921	63.041	4.565.250	2,2969	8,17	6,36	8
VAN	2014	286.990	342.414	888.182	2,2969	8,17	6,36	5
YALOVA	2014	3.153	40.399	1.509.144	2,2969	8,17	6,36	3
YOZGAT	2014	79.495	97.628	1.593.814	2,2969	8,17	6,36	10
ZONGULDAK	2014	80.241	112.451	4.959.203	2,2969	8,17	6,36	13
ADANA	2015	1.515.949	499.689	42.837.975	2,9228	8,81	5,71	8
ADIYAMAN	2015	356.498	158.401	3.521.045	2,9228	8,81	5,71	7
AFYON	2015	86.269	142.526	9.621.830	2,9228	8,81	5,71	16
AĞRI	2015	113.225	170.824	2.780.201	2,9228	8,81	5,71	13
AKSARAY	2015	18.879	85.295	6.047.344	2,9228	8,81	5,71	2
AMASYA	2015	12.567	67.230	7.228.616	2,9228	8,81	5,71	5
ANKARA	2015	9.587.639	976.738	214.777.220	2,9228	8,81	5,71	38

EK A: Test İçin Kullanılan Veriler (Devam)

İL	Yıl	Satış	Öğrenci	Hane Eğitim	Dolar	Tüfe	Üfe	Müşteri
		Hacmi	Sayıları	Harcama tutarı	Kuru			Sayısı
ANTALYA	2015	1.047.142	436.219	48.547.714	2,9228	8,81	5,71	42
ARDAHAN	2015	22.197	22.615	803.257	2,9228	8,81	5,71	2
ARTVİN	2015	15.206	30.024	2.692.079	2,9228	8,81	5,71	4
AYDIN	2015	69.731	183.368	12.883.311	2,9228	8,81	5,71	20
BALIKESİR	2015	147.840	193.222	21.890.322	2,9228	8,81	5,71	19
BARTIN	2015	23.864	39.849	1.337.834	2,9228	8,81	5,71	5
BATMAN	2015	182.830	173.560	2.765.804	2,9228	8,81	5,71	7
BAYBURT	2015	48.758	16.439	296.928	2,9228	8,81	5,71	3
BİLECİK	2015	27.813	37.627	2.666.748	2,9228	8,81	5,71	6
BİNGÖL	2015	100.720	63.764	511.058	2,9228	8,81	5,71	9
BİTLİS	2015	47.868	100.957	467.455	2,9228	8,81	5,71	11
BOLU	2015	21.893	48.945	4.676.286	2,9228	8,81	5,71	5
BURDUR	2015	7.821	45.570	3.379.612	2,9228	8,81	5,71	11
BURSA	2015	1.288.740	506.809	48.285.847	2,9228	8,81	5,71	24
ÇANAKKALE	2015	41.500	76.178	8.570.241	2,9228	8,81	5,71	9
ÇANKIRI	2015	12.351	29.544	2.188.460	2,9228	8,81	5,71	3
ÇORUM	2015	29.093	107.752	10.389.470	2,9228	8,81	5,71	8
DENİZLİ	2015	360.970	187.558	13.973.186	2,9228	8,81	5,71	12
DIYARBAKIR	2015	680.948	504.658	7.656.339	2,9228	8,81	5,71	9
DÜZCE	2015	9.783	70.163	2.517.234	2,9228	8,81	5,71	3
EDİRNE	2015	49.904	59.239	11.679.249	2,9228	8,81	5,71	8
ELAZIĞ	2015	419.821	139.050	7.962.516	2,9228	8,81	5,71	9
ERZİNCAN	2015	85.628	42.963	1.275.982	2,9228	8,81	5,71	3
ERZURUM	2015	314.388	185.530	3.560.451	2,9228	8,81	5,71	13
ESKİŞEHİR	2015	132.542	136.957	21.798.417	2,9228	8,81	5,71	9
GAZİANTEP	2015	1.136.621	534.183	21.709.797	2,9228	8,81	5,71	16
GİRESUN	2015	41.059	81.059	7.944.979	2,9228	8,81	5,71	8
GÜMÜŞHANE	2015	14.583	22.448	1.557.652	2,9228	8,81	5,71	6
HAKKARİ	2015	7.299	75.406	93.032	2,9228	8,81	5,71	4
HATAY	2015	347.457	376.791	22.165.725	2,9228	8,81	5,71	20
İĞDIR	2015	22.691	40.406	739.879	2,9228	8,81	5,71	6
ISPARTA	2015	88.218	86.159	3.496.042	2,9228	8,81	5,71	12
İSTANBUL	2015	16.037.941	2.598.449	494.043.775	2,9228	8,81	5,71	196
İZMİR	2015	3.044.434	699.420	112.367.015	2,9228	8,81	5,71	79
KAHRAMANMARAŞ	2015	314.135	288.425	16.233.121	2,9228	8,81	5,71	10
KARABÜK	2015	1.379	39.392	991.212	2,9228	8,81	5,71	3
KARAMAN	2015	23.098	50.774	1.104.596	2,9228	8,81	5,71	4
KARS	2015	7.987	73.114	2.777.597	2,9228	8,81	5,71	3

EK A: Test İçin Kullanılan Veriler (Devam)

İL	Yıl	Satış	Öğrenci	Hane Eğitim	Dolar	Tüfe	Üfe	Müşteri
		Hacmi	Sayıları	Harcama tutarı	Kuru			Sayısı
KASTAMONU	2015	4.433	60.128	5.962.914	2,9228	8,81	5,71	4
KAYSERİ	2015	695.649	290.521	16.540.438	2,9228	8,81	5,71	25
KIRIKKALE	2015	7.798	55.341	2.055.876	2,9228	8,81	5,71	2
KIRKLARELİ	2015	9.524	53.613	6.403.591	2,9228	8,81	5,71	5
KİRŞEHİR	2015	8.541	27.006	3.547.541	2,9228	8,81	5,71	5
KİLİS	2015	38.281	33.076	793.261	2,9228	8,81	5,71	2
KOCAELİ	2015	131.879	345.696	22.989.304	2,9228	8,81	5,71	19
KONYA	2015	1.595.051	489.825	39.528.674	2,9228	8,81	5,71	26
KÜTAHYA	2015	78.033	102.693	6.917.080	2,9228	8,81	5,71	11
MALATYA	2015	579.471	193.016	12.633.167	2,9228	8,81	5,71	8
MANİSA	2015	229.144	258.949	17.125.170	2,9228	8,81	5,71	30
MARDİN	2015	304.373	223.247	1.894.293	2,9228	8,81	5,71	15
MERSİN	2015	319.025	380.329	31.140.443	2,9228	8,81	5,71	14
MUĞLA	2015	112.456	152.049	11.033.015	2,9228	8,81	5,71	20
MUŞ	2015	128.026	138.560	149.573	2,9228	8,81	5,71	10
NEVŞEHİR	2015	5.296	58.813	3.919.510	2,9228	8,81	5,71	2
NİĞDE	2015	19.522	76.461	4.072.430	2,9228	8,81	5,71	6
ORDU	2015	80.867	137.468	6.489.201	2,9228	8,81	5,71	11
OSMANİYE	2015	156.075	125.343	7.837.366	2,9228	8,81	5,71	7
RİZE	2015	70.848	75.032	3.494.186	2,9228	8,81	5,71	7
SAKARYA	2015	171.631	185.885	11.511.406	2,9228	8,81	5,71	14
SAMSUN	2015	1.229.062	283.550	36.290.226	2,9228	8,81	5,71	16
SİİRT	2015	88.116	99.279	793.288	2,9228	8,81	5,71	3
SİNOP	2015	23.367	36.442	2.168.114	2,9228	8,81	5,71	4
SİVAS	2015	148.004	128.867	5.184.973	2,9228	8,81	5,71	10
ŞANLIURFA	2015	317.608	600.890	9.174.768	2,9228	8,81	5,71	24
ŞIRNAK	2015	43.205	160.341	563.060	2,9228	8,81	5,71	5
TEKİRDAĞ	2015	97.512	159.938	18.885.018	2,9228	8,81	5,71	8
TOKAT	2015	144.477	120.654	7.359.416	2,9228	8,81	5,71	14
TRABZON	2015	325.840	152.474	25.218.514	2,9228	8,81	5,71	18
TUNCELİ	2015	28.674	12.069	226.679	2,9228	8,81	5,71	1
UŞAK	2015	202.281	62.951	4.877.829	2,9228	8,81	5,71	10
VAN	2015	300.745	341.924	948.995	2,9228	8,81	5,71	9
YALOVA	2015	1.188	40.341	1.612.474	2,9228	8,81	5,71	1
YOZGAT	2015	96.131	97.488	1.702.941	2,9228	8,81	5,71	9
ZONGULDAK	2015	114.624	112.290	5.298.755	2,9228	8,81	5,71	14



ÖZGEÇMİŞ

Ad-Soyad : Ayhan Yangın

Doğum Tarihi ve Yeri: 28.12.1986, Beykoz

E-posta : ayhanyangin05@gmail.com

ÖĞRENİM DURUMU:

- **Ön Lisans** : 2006, Ahmet Yesevi Üniversitesi, Bilgisayar Programcılığı
- **Lisans**: 2011, Anadolu Üniversitesi, İşletme
- **Yüksek Lisans**: Devam etmektedir, İstanbul Aydın Üniversitesi, Bilgisayar Mühendisliği

MESLEKİ DENEYİM VE ÖDÜLLER

- 11.2016- : Gökkuşluğu Dağıtım A.Ş.
Bilgi Sistemleri Uzmanı
- 10.2016 : UTT A.Ş.
Bilgi Sistemleri Uzmanı
- 08.2004 : Pulse Bilgisayar
Staj