



**T.C. İSTANBUL TİCARET
ÜNİVERSİTESİ**

FEN BİLİMLERİ ENSTİTÜSÜ

PERAKENDE SEKTÖRÜNDE TALEP TAHMİNİ

Muhammed Resul AYDIN

**Danışman
Prof. Dr. Osman YAZICIOĞLU**

**YÜKSEK LİSANS TEZİ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
İSTANBUL-2019**

KABUL VE ONAY SAYFASI

Muhammed Resul AYDIN tarafından hazırlanan "**Perakende Sektöründe Talep Tahmini**" adlı tez çalışması 27/06/2019 tarihinde aşağıdaki jüri üyeleri önünde başarı ile savunularak, İstanbul Ticaret Üniversitesi Fen Bilimleri Enstitüsü **Endüstri Mühendisliği Anabilim Dalı**'nda **YÜKSEK LİSANS TEZİ** olarak kabul edilmiştir.

Danışman

Prof. Dr. Osman YAZICIOĞLU
İstanbul Ticaret Üniversitesi



Jüri Üyesi

Prof. Dr. Oğuz BORAT
İstanbul Ticaret Üniversitesi

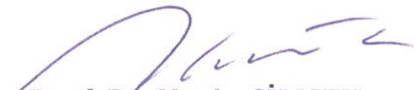


Jüri Üyesi

Doç. Dr. Nezir AYDIN
Yıldız Teknik Üniversitesi



Onay Tarihi : 09.07.2019



Prof. Dr. Necip ŞİMŞEK
Enstitü Müdürü

AKADEMİK VE ETİK KURALLARA UYGUNLUK BEYANI

İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir tahrifat yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversitede veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim.

20.05.2019


Muhammed Resul AYDIN

İÇİNDEKİLER

İÇİNDEKİLER	i
ÖZET	iv
ABSTRACT	v
TEŞEKKÜR.....	vi
ŞEKİLLER DİZİNİ	vii
TABLolar DİZİNİ.....	viii
KISALTMALAR DİZİNİ.....	ix
1. GİRİŞ	1
2. LİTERATÜR ÖZETİ.....	3
2.1. Perakende Sektörü Literatür Özeti.....	3
2.2. Talep Tahmini Literatür Özeti	5
3. PERAKENDECİLİK KAVRAMI.....	10
3.1. Perakende ve Perakende Sektörü Tanımları	10
3.2. Perakendecilik Sektörünün Tarihsel Gelişimi	11
3.3. Perakende Satış Kanalları	13
3.3.1. Mağazalı perakendecilik	14
3.3.2. Mağazasız perakendecilik.....	16
3.4. Türkiye’de Perakende Sektörü.....	18
3.5. Dünya’da ve Türkiye’de Tüketici Eğilimleri.....	19
3.6. Hanehalkı Tüketim Harcamaları.....	20
4. TALEP TAHMİN YÖNTEMLERİ.....	22
4.1. Talep Tahminin Önemi	22
4.2. Talep Tahmininin Sınıflandırılması.....	22
4.3. İstatistiksel Yöntemlerle Talep Tahmini.....	23
4.3.1. Regresyon analizi yöntemi.....	24
4.3.2. Korelasyon yöntemi	25
4.3.3. Basit ortalamalar yöntemi	25
4.3.4. Son dönem talebi yöntemi	26
4.3.5. Hareketli ortalamalar yöntemi	26
4.3.6. Ağırlıklı ortalama yöntemi.....	26
4.3.7. Ağırlıklı hareketli ortalama yöntemi.....	27
4.3.8. Üssel düzeltme yöntemi.....	27
4.3.9. Simülasyon (benzetim) yöntemiyle talep tahmini	27

4.3.10. Zaman serileri analizine dayanan talep tahmin yöntemleri	28
4.3.11. Yapay sinir ağları yöntemiyle talep tahmini.....	33
5. YAPAY SİNİR AĞLARI	34
5.1. Yapay Sinir Ağı Tanımları	34
5.2. Yapay Sinir Ağlarının Tarihçesi.....	35
5.3. Yapay Sinir Ağlarının Genel Özellikleri	35
5.4. Yapay Sinir Ağlarının Avantajları ve Dezavantajları.....	36
5.5. Yapay Sinir Ağlarının Temel Yapısı ve Temel Bileşenleri.....	36
5.5.1. Biyolojik sinir hücresi.....	37
5.5.2. Yapay sinir hücresi	39
5.6. Yapay Sinir Ağlarının Eğitimi ve Testi	40
5.7. Yapay Sinir Ağlarının Sınıflandırılması	40
5.7.1. Tipine göre yapay sinir ağları	41
5.7.2. Öğrenme yöntemine göre yapay sinir ağları.....	41
5.7.3. Yapısına göre yapay sinir ağları	43
5.7.4. Katman sayılarına göre yapay sinir ağları	43
5.8. Yapay Sinir Ağlarında Öğrenme	54
5.8.1. Hata-düzeltilme öğrenimi	54
5.8.2. Bellek tabanlı öğrenme	55
5.8.3. Hebbian öğrenme.....	55
5.8.4. Rekabetçi öğrenme	55
5.8.5. Boltzman öğrenmesi	56
5.8.6. Hopfield öğrenme kuralı.....	56
5.8.7. Delta kuralı	56
5.8.8. Kohonen kuralı	56
6. TALEP TAHMİN UYGULAMASI	57
6.1. Veri	57
6.2. Yapay Sinir Ağları Uygulaması.....	61
6.2.1. YSA ile dana eti talep tahmini.....	61
6.2.2. YSA ile kuzu eti talep tahmini.....	62
6.2.3. YSA ile tavuk eti talep tahmini.....	63
6.3. ARIMA Modellerinin Uygulanması.....	65
6.3.1. Kuzu eti talebi.....	65
6.3.2. Dana eti talebi	67
6.3.4. Tavuk eti talebi	69
6.4. Yapay Sinir Ağları ve ARIMA Modellerinin Karşılaştırılması.....	70

7. SONUÇ VE ÖNERİLER.....	73
KAYNAKLAR.....	74
ÖZGEÇMİŞ.....	81



ÖZET

Yüksek Lisans Tezi

PERAKENDE SEKTÖRÜNDE TALEP TAHMİNİ

Muhammed Resul AYDIN

**İstanbul Ticaret Üniversitesi
Fen Bilimleri Enstitüsü
Endüstri Mühendisliği Anabilim Dalı**

Danışman: Prof. Dr. Osman YAZICIOĞLU

2019, 81 sayfa

İşletmeler, mevcut durumlarını koruyabilmek ve geliştirebilmek için değişen müşteri istek ve ihtiyaçlarını anlayabilmeli ve iyi bir plan çerçevesinde makul çözümler üretmelidirler. İşletmeler için yadsınamaz öneme sahip talep tahmininde uygulanan birçok yöntem bulunmaktadır. Yapay sinir ağları, kullanımı son yıllarda yaygınlaşan, neden-sonuç ilişkisine dayalı analizlerde bulunabilen bir yöntem olup, tutarlı ve güvenilir sonuçlar sunan istatistiksel bir talep tahmin yöntemidir.

Çalışmada istatistiksel talep tahmin yöntemlerinden yapay sinir ağı modelleri, doğruluğunun ve tahmin performansının gösterilmesi açısından, zaman serisi analizleri modellerinden olan ARIMA modeli ile kıyaslanmıştır. Kıyaslama neticesinde yapay sinir ağları için dana, kuzu ve tavuk etleri talep tahminine ait MAPE değerleri sırasıyla %2.4279, %1.2077 ve %1.424 iken ARIMA modelleri için ise MAPE değerleri sırasıyla %15.7521, %29.280 ve %10.3951 olarak elde edilmiştir. Elde edilen değerler neticesinde yapay sinir ağları ile oluşturulan tahmin modellerinin bu çalışmada daha iyi performans sunduğu gözlemlenmiş ve örneklemin elde edildiği yer için %99 güven aralığında yapay sinir ağları ile gelecek 8 haftalık dönem için talep miktarları tahmin edilmiştir.

Çalışmadan elde edilen bulguların, küçük ve orta ölçekli yerel perakende firmalarının talep tahmini metotlarından faydalanarak gelişim göstermesine ve gittikçe kızışan rekabet ortamında ayakta kalmasına ve literatüre katkı sunması beklenmektedir.

Anahtar Kelimeler: ARIMA, perakende sektörü, talep tahmini, yapay sinir ağları

ABSTRACT

M.Sc. Thesis

DEMAND FORECASTING IN RETAIL INDUSTRY

Muhammed Resul AYDIN

**İstanbul Commerce University
Graduate School of Applied and Natural Sciences
Department of Industrial Engineering**

Supervisor: Prof. Dr. Osman YAZICIOĞLU

2019, 81 pages

Companies should understand the changing customers' needs and demands then should produce new plausible policies to protect and improve their current status. The purpose of the forecasting is that to predict possible situations companies might face in the future and take actions in advance. There are a lot of methods used for demand forecasting. Artificial neural networks, based on cause and effect relationship, are a statistical methods which are widely and efficiently used in solution of demand forecasting. In this study, artificial neural networks and ARIMA models have been discussed to show the accuracy and reliability of artificial neural networks. Results demonstrate that ANN (artificial neural network) performs better than ARIMA models with a Mean Absolute Percentage Error (MAPE) of %2.4279 for beef demand forecasting, %1.2077 for lamb demand forecasting and %1.424 for chicken demand forecasting whereas ARIMA has MAPE of %15.7521, %29.280, and %10.3951 respectively. According to the comparison of two statistical methods, artificial neural networks are more reliable and consistent in this study to build appropriate model. In this study, demand forecasting practice is made with artificial neural networks with %99 confidence intervals by using past data belonging to a supermarket for the next upcoming 8 week. The aim of this study to show an example for other firms to keep up with the times and contribute to literature.

Keywords: ARIMA, artificial neural networks, demand forecasting, retailing industry

TEŐEKKÜR

Bu arařtırma için beni yönlendiren, karşılařtıđım zorlukları bilgi ve tecrübesi ile ařmamda yardımcı olan deđerli Danıřman Hocam Prof. Dr. Osman Yazıcıođlu'na teőekkürlerimi sunarım.

Tezimde karşılařtıđım çeřitli zorluklarda yardımlarıyla yol gösteren deđerli Hocam Prof. Dr. Necip Őimőek'e ve Sayın Göksel Kıbıř'a teőekkürlerimi sunarım.

Tezimin her ařamasında beni yalnız bırakmayan aileme ve eřime sonsuz sevgi ve saygılarımı sunarım.

Muhammed Resul
AYDIN
İSTANBUL, 2019



ŞEKİLLER DİZİNİ

	Sayfa
Şekil 3.1. Hanehalkı tüketim harcamaları	21
Şekil 5.1. Çok katmanlı bir yapay sinir ağı	37
Şekil 5.2. Sinir hücresi	38
Şekil 5.3. Yapay sinir hücresinin matematiksel yapısı.....	39
Şekil 5.4. YSA'ların sınıflandırılması.....	41
Şekil 5.5. İleri beslemeli geri yayılım yapay sinir ağı yapısı	45
Şekil 6.1. 2017-2018 yılları arasında gerçekleşen 3 farklı et türü talep miktarları grafiği.....	61
Şekil 6.2. WEKA paket programında dana eti talep tahmin grafiği	62
Şekil 6.3. WEKA paket programında kuzu eti talep tahmin grafiği	63
Şekil 6.4. WEKA paket programında tavuk eti talep tahmin grafiği	64
Şekil 6.5. 2017-2018 yılları arasında gerçekleşen kuzu eti talep miktarları grafiği	65
Şekil 6.6. EViews paket programı ile birim kök testi	66
Şekil 6.7. Bilgi kriterleri yöntemi ile en uygun modelin tespit aşaması	66
Şekil 6.8. EViews paket programında kuzu eti talep tahmin grafiği.....	67
Şekil 6.9. EViews paket programı ile birim kök testi	67
Şekil 6.10. EViews paket programı ile birim kök testi	68
Şekil 6.11. EViews paket programı ile birim kök testi	68
Şekil 6.12. EViews paket programında dana eti talep tahmin grafiği.....	68
Şekil 6.13. EViews paket programı ile birim kök testi	69
Şekil 6.14. Uygun modelin tespiti için modellerin kıyaslanması.....	69
Şekil 6.15. EViews paket programında tavuk eti talep tahmin grafiği	70

TABLULAR DİZİNİ

	Sayfa
Tablo 3.1. Hanehalkı tüketim harcamalarının türlerine göre dağılım tablosu.....	20
Tablo 5.1. Sinir sistemi ile YSA'nın benzerlikleri.....	39
Tablo 6.1. 2017 – 2018 yılları arasında gerçekleşen 3 farklı et türü talep miktarları	58
Tablo 6.2. Dana eti talep tahmin hatasının doğruluk ölçütleri	62
Tablo 6.3. Kuzu eti talep tahmin hatasının doğruluk ölçütleri.....	63
Tablo 6.4. Tavuk eti talep tahmin hatasının doğruluk ölçütleri.....	64
Tablo 6.5. Dana, kuzu ve tavuk eti için ileriye dönük 7 haftalık talep tahmin değerleri.....	64
Tablo 6.6. ARIMA modelleri ile elde edilen tahmin değerleri	70
Tablo 6.7. YSA ve ARIMA modellerinin dana eti tahmin hatasının doğruluk ölçütleri karşılaştırması.....	71
Tablo 6.8. YSA ve ARIMA modellerinin kuzu eti tahmin hatasının doğruluk ölçütleri karşılaştırması.....	71
Tablo 6.9. YSA ve arıma modellerinin tavuk eti tahmin hatasının doğruluk ölçütleri karşılaştırması.....	71

KISALTMALAR DİZİNİ

Çalışma içerisinde kullanılan kısaltmalar açıklamaları ile birlikte aşağıda verilmiştir.

Kısaltmalar	Açıklama
ADF	Augmented Dickey-Fuller
ANN	Artificial neural network
AR	Otoregresif
ARIMA	Otoregresif entegre hareketli ortalamalar yöntemi
ARMA	Otoregresif Hareketli Ortalama
BIC	Bayesian Information Criterion
ÇKA	Çok katmanlı algılayıcı
DF	Dickey Fuller
HKO	Hata kareleri ortalamaları
HKT	Hata kareleri toplamı
MA	Hareketli Ortalama
MAD	Ortalama standart sapma
MAE	Ortalama mutlak hata
MAPE	Ortalama mutlak yüzde hata
MSE	Ortalama hata
OH	Ortalama hata
OMH	Ortalama mutlak hata
OMYH	Ortalama mutlak yüzde hata
RMSE	Kök ortalama kare hata
SARIMA	Seasonal Otoregresif entegre hareketli ortalamalar yöntemi
TDK	Türk dil kurumu
TÜİK	Türkiye istatistik kurumu
WEKA	Waikato Environment for Knowledge Analysis
YSA	Yapay sinir ağları
YSH	Yapay sinir hücresi

1. GİRİŞ

Günümüzde meydana gelen kızgın rekabet ortamı neticesinde, kurumlar rekabet ortamında ayakta kalabilmek için gelecek planlamasına ihtiyaç duymaktadır. Rekabetçi piyasa, ekonomik ve politik dalgalanmalar neticesinde geleceği öngörebilme zorlaşmakta bu sebeple doğru öngörmenin önemi artmaktadır. Bu sebeplerden ötürü birçok kurum ve araştırmacı, tahmin ile alakalı çeşitli araştırmalar gerçekleştirmektedirler. Günümüzde talebi etkileyen etkenlerin çok olması ve bunların birbirleri ile olan ilişkilerinin karmaşık olması sebebiyle, tecrübe ve sezgi ile yapılan tahminler yetersiz kalmaktadır. Bu sebeple istatistiksel yöntemlerle talep tahmini büyük önem arz etmektedir. Talep tahmin yöntemlerinde kullanılan teknikler, uygulamalı istatistiğin konuları içerisinde yer almaktadır (Kobu, 1994).

Perakende sektöründe de gittikçe kızışan rekabet sonucu gelen değişimler, tüm sektör oyuncularını bu değişime ayak uydurmaya zorlamıştır. Rekabete, değişime ayak uyduramayan firmaların ya büyük kayıplar verdiği ya da piyasadan silindiğine tanıklık edilmiştir. Şüphesiz bu durum en çok tüketici yararına olmuştur. Geleneksel yöntemlere göre çok daha kısa zamanda, iyi ve kaliteli çok seçenekli hizmete ulaşan müşteriler son dönemlerde artık kişiye özel hizmet talep etmektedir (KPGM, 2018).

Yapay sinir ağları yönteminden son yıllarda, birçok alanda olduğu gibi, talep tahmin çalışmalarında da sıkça faydalanılmıştır. Bu tez kapsamında yapay sinir ağlarının talep tahmininde uygulanması ile etkin sonuçlar elde edileceğinin gösterilmesi hedeflenmiştir.

Araştırmanın örneklemini İstanbul-Ümraniye sınırları içerisinde bulunan bir süpermarketten alınan veriler oluşturmaktadır. Sistematiik veri toplama yöntemine başvurularak 2017-2018 yılları arasında gerçekleşen yaklaşık 104 haftalık satış miktarları örneklem olarak belirlenmiştir.

Bu çalışmanın amacı; bir süpermarketten elde edilen veriler yardımıyla yapay sinir ağları ve zaman serisi tahmin yöntemlerinin uygulanması, uygulanan iki modelin geçmişe dönük tahmin doğruluklarının kıyas edilerek en uygun sonuç sağlayan modelin seçilmesi, seçilen bu model yardımıyla gelecek dönem taleplerinin haftalar

itibariyle tahmin edilmesidir. Uygulamada YSA modeli WEKA paket programı ile ARIMA modeli ise EViews paket programıyla oluşturulmuştur.

Çalışmadan elde edilen bulguların, küçük ve orta ölçekli yerel perakende firmalarının talep tahmini metotlarından faydalanarak gelişim göstermesine ve gittikçe kızışan rekabet ortamında ayakta kalmasına ve literatüre katkı sunması beklenmektedir.

İkinci bölümde talep tahmini ve perakende sektöründe talep tahmini hakkında literatür araştırmaları gerçekleştirilmiştir.

Üçüncü bölümde perakende sektörü hakkında detaylı bilgiler verilmiştir. Perakende sektörünün ekonomideki yeri, tarihçesi, önemi gibi konulara değinilmiştir.

Dördüncü bölümde talep tahmini ve yöntemleri hakkında bilgiler sunulmuştur. Çeşitli tahmin yöntemlerinden bahsedilmiştir. Zaman serisi analizlerinin uygulamada yapay sinir ağları ile karşılaştırılmasından ötürü, zaman serisi analizleri hakkında daha fazla bilgi sunulmuştur.

Beşinci bölümde yapay sinir ağları ile ilgili genel bir giriş yapıldıktan sonra yapay sinir ağları ile alakalı detaylı bilgiler sunulmuştur. Tez kapsamında uygulanacak ÇKA (Çok Katmanlı Algılayıcılar) modeli daha ayrıntılı olarak anlatılmıştır.

Altıncı bölümde, uygulama kapsamında yapılan çalışmalar ayrıntılı bir şekilde sunulmuştur. Yapay sinir ağları ve ARIMA modelleri ile talep tahmini yapılmış, sonuçlar incelenerek iki model arasında kıyaslama yapılmıştır. Daha başarılı tahmin performansı sunan model ile ileriye dönük haftalık talep tahminleri gerçekleştirilmiştir.

Son bölümde ise uygulama bölümünde elde edilen sonuçlar değerlendirilerek ileriki muhtemel çalışmalara yön verme hedefiyle çeşitli öneriler sunulmuştur.

2. LİTERATÜR ÖZETİ

Literatür özeti, perakende talep tahmini literatür özeti ve talep tahmin literatür özeti olmak üzere iki başlık altında incelenmiştir.

2.1. Perakende Sektörü Literatür Özeti

Schmit ve Kaiser (2006), önümüzdeki 10 yıl için süt ve peynir talebini tahmin etmişlerdir. Amerika Birleşik Devletleri sınırları içerisinde gerçekleştirilen çalışmada, o dönemde süt tüketiminde azalma, peynir tüketiminde ise artış gözükmekteydi. Çalışmada bu trendin sebepleri irdelenerek, süt ve süt ürünleri üreticilerine gelecek tahmin değerleri sunularak, yardımcı olmak hedeflenmiştir. Çalışmada 2006-2015 yılları için talep tahmin çalışması gerçekleştirilmiştir.

Eren ve Satoğlu (2007), Perakende Giyim sektöründe faaliyette bulunan mağaza zincirinin bir mağazası için yapay sinir ağları ile talep tahmini gerçekleştirmişlerdir. Çalışma için biri talebi düzenli olan, biri de mevsimsel talep özelliğine sahip ürünlere ait talep verileri toplanmıştır. Hava durumu, indirim ve mağazaya gelen müşteri sayısı gibi etkenler göz önüne alınarak her iki ürün için iki farklı yapay sinir ağı modeli oluşturulmuştur. Birinci tip model mevsimselliği dikkate alırken diğer model ise mevsimsel olmayan yapıdadır. Kurulan iki model ile tahmin yapılarak, Regresyon Katsayısı ve Hataların Karelerinin Ortalaması (MSE) çıktılarına göre modeller başarılı sonuçlar vermiştir.

Sun, Au, Choi, Yu, (2008), çalışmalarında en uygun talep modelini belirlemek için gelişimsel yapay sinir ağları modelini kullanmışlardır. Örneklem bir giyim mağazasının verilerinden elde edilmiştir. Yapay sinir ağları ve geleneksel tahmin metotları ile tahmin modelleri oluşturulmuştur. Çalışma sonunda yapay sinir ağları ile kurulan modelin diğer tahmin modellerinin yanı sıra SARIMA modelinden de daha iyi performans sunduğu gözlemlenmiştir.

Gökcel (2009), çalışmasında perakende sektörünü kategorisel temelde inceleyerek, kategoriler arası cirosal olarak sıralama yaparak hangi ürün grubuna ne kadar ağırlık verilmesi gerektiğini belirlemiştir. 2 yıllık satış verilerine göre Perakende sektöründe

Kuru Gıda kategorisine ait en yüksek cirosal getiriye saęlayan yaę kategorisi için en uygun tahmin metodunu arařtırmıřtır. Akabinde Deterjan-Kaęıt-Kozmetik kategorisinden bir ürüne ait aylık, bölgesel ve maęaza satıřlarına bakarak atıl stok veya yetersiz stok durumunu ortadan kaldırmak için geliřtirdięi ekonomik sipariř miktarı modeli yardımıyla elde edilen sonuçları mevcut durumla karřılařtırarak yapılan iyileřtirmeleri aıklamıřtır.

Hung, Tsai ve Wu (2014), rekabet kořulları gittike sertleřen perakende sektörüne, yatırım zamanlama ve yönetim stratejilerine katkı sunması için talep tahmini alıřması gerekleřtirmiřlerdir. Talep tahmini yapılırken, doęru sonuçlar elde edilmesine engel olan mevsim etkisi gibi durumlar alıřmalarında göz önünde tutulmuřtur. Deęiřtirilmiř Lotka-Volterra modeli tahmin için kullanılmıřtır. Tahmin sonuçlarının doęruluęu ortalama kesin hatalar (MAE) ile ölçölmüřtür.

Donselaar, Peters, Jong ve Broekmeulen (2016), alıřmalarında promosyon zamanlarında ürüyen besinler için analiz ve talep tahmini alıřmıřlardır. Hareketli ortalamalar ile birlikte regresyon analizi ile de talep tahmin modeli oluřturulmuřtur.

Zhang, Chan, Srivastava, Park (2017), yüksek fiyatlı ürünler için talep öngörme ve fiyat optimizasyonu gerekleřtirmiřlerdir. alıřmada fiyatlandırma ve fiyat optimizasyonu ile karar destek mekanizmasına katkı hedeflenmiřtir. alıřmanın örneklemini, 45 farklı perakende satıř noktasından, 2.5 yıllık gemiř satıř verileri kullanılarak elde edilmiřtir. Makine öęrenmesine dayanarak Regresyon karar aęacı ile oluřturulan talep modelinde haftalık talep tahmini yapılmıřtır.

Mou, Robb ve DeHoratius (2018), alıřmalarında perakende sektörü maęaza operasyonları için literatür özeti ve arařtırma yönlendirmeleri alıřmıřlardır. 2008 ile 2016 yılları arasındaki konu ile alakalı 255 alıřma incelenmiřtir.

Tanizaki, Hoshino, Shimmura ve Takenaka (2019), makine öęrenmesi ve istatistiksel analiz kullanarak restoranlarda talep tahmini gerekleřtirmiřlerdir. Maęaza konumu, hava durumu, grup organizasyonları gibi talebi etkileyen faktörler hesaba katılarak maęazaya özgü bilgiler ile talep tahmin modeli oluřturularak talep tahmini uygulamıřtır.

2.2. Talep Tahmini Literatür Özeti

Hamzaçebi ve Kutay (2004), uzun dönemli elektrik enerjisi tüketimi tahmininde yapay sinir ağları modellerinden faydalanmışlardır. Elde edilen sonuçlar neticesinde, yapay sinir ağlarının elektrik enerjisi tüketimi için yapay sinir ağlarının başarılı bir tahmin aracı olduğu saptanmıştır.

Çuhadar ve Kayacan (2005), çalışmalarında Turizm Bakanlığı tarafından yıllık olarak yayımlanan “Konaklama İstatistikleri” bülteninden 1990-2002 yıllarına ait verilerden yararlanarak, yapay sinir ağları metodu ile gelecek dönemler için tahmin çalışmışlardır.

Kızılaslan (2008), yapay sinir ağları algoritmaları ile saatlik, günlük, haftalık ve aylık doğalgaz enerjisi öngörüsü için uygun modellerin bulunmasını amaçlamıştır. Doğalgaz tüketiminin doğru öngörülmesinin dağıtıcı ve tüketici açısından önemine değinen yazar, ilk olarak gaz tüketimine etki eden sebepleri belirlemek amacıyla kapsamlı faktör analizi gerçekleştirmiştir. Elde edilen sonuçlar yardımıyla geri beslemeli yapay sinir ağları modelleri oluşturulmuştur. Çalışmada yedi farklı yapay sinir ağları algoritması uygulanarak, uygulanan algoritmalar karşılaştırılmıştır.

Olgun (2009), çalışmasında tedarik zinciri yönetiminde talep yönetiminin önem ve kapsamından bahsedilmiş, akabinde talep yönetiminde kullanılan talep tahmin yöntemlerini incelenmiştir. Yapılan talep tahminlerinin başarısını etkileyen önemli sebeplere incelenerek, literatürde mevcut olan nicel, nitel ve yapay zekâ tabanlı yöntemler sunmuştur. Daha sonra yapay zekâ tabanlı talep tahmin metodlarından biri olan yapay sinir ağları yöntemini detaylı bir şekilde inceleyerek, bir uygulama problemi üzerinde metodun başarısını test etmiştir.

Gözcü (2009), 1991-2008 yılları arasındaki zaman zarfında, havayolu ulaşımına ait dinamikler ile 2009 yılı için aylık yolcu sayılarının öngörülmesini ve elde edilen öngörülerin güvenilirliğinin değerlendirmiştir.

Kandananond (2011), Tayland’da 1986-2000 yılları arasındaki elektrik tüketim değerlerini kullanarak farklı tahmin modelleri ile elektrik tüketimi talep tahmini gerçekleştirmiştir. Yapay sinir ağları, ARIMA ve çoklu lineer regresyon ile tahmin modelleri oluşturularak, oluşturulan modellerin performansları kıyaslanmıştır.

Çalışma sonuçlarına göre modellerin ortalama hata yüzdeleri (MAPE); yapay sinir ağları için %0.996, ARIMA için %2.80981 ve çoklu lineer regresyon için %3.2604527 olarak tespit edilmiştir. Bu hata oranlarına da dayanarak çalışmada performansı en yüksek model yapay sinir ağları olarak belirlenmiştir.

Karaatlı, Helvacıoğlu, Ömürbek ve Tokgöz (2012), yeni otomobil satış miktarlarının yapay sinir ağları metoduyla tahmin ederek otomotiv sektörü ile alakalı politikaların belirlenmesine katkı sunmaya çalışmışlardır.

Turhan, C., Gökçen, G., Kazanasmaz, Z.T.,(2013), binalarda enerji tüketimini öngörebilmek amacıyla yapay sinir ağları ve bulanık mantık modellerinden faydalanmıştır. Çalışmanın örneklemini İzmir'in 3 farklı ilçesinde bulunan 148 bina oluşturmaktadır. Bu binaların mimari projeleri ve ısı hesap raporlarından elde edilen veriler modeller ve yazılım için giriş değişkenlerini oluşturmaktadır. Dört farklı yapay sinir ağı modeli ve bir bulanık mantık modeli oluşturulduktan sonra eğitilerek test edildi. Test sonuçlarına göre yapay sinir ağlarının ortalama mutlak yüzde hata (MAPE) %4,1 ve ortalama mutlak sapma (MAD) 6,57 olarak tespit edilmiştir. Bulanık mantık modelinin ise ortalama mutlak yüzde hatası %4,86 ve ortalama mutlak sapması 7,59 olarak tespit edilmiştir. Elde edilen sonuçlar ışığında yapay sinir ağlarının daha doğru tahminler sunduğu tespit edilmiştir.

Solak (2013), çalışmasında Otoregresif Entegre Hareketli Ortalamalar (ARIMA) modeli ile Türkiye'nin 2012-2020 dönemleri için toplam petrol talebi ve ulaştırma sektörü petrol talebinin tahmin edilmesini çalışmıştır.

Es, Kalender ve Hamzaçebi (2014), çalışmalarında Türkiye net enerji talebini tahmin edebilmek için 1970-2000 yılları arasındaki Gayri Safi Yurtiçi Hâsıla, nüfus, ithalat ve ihracat gibi değişkenleri yapay sinir ağları modelinin girdisi olarak kullanarak talep tahmin modeli oluşturmuştur. Kurulan bu model ile 2011-2025 yılları arası Türkiye net enerji talebini tahmin çalışmışlardır.

Mehmet Karahan (2015), çalışmasında ihracat miktarlarının tahmini için ARIMA ve yapay sinir ağları modellerini kıyaslamıştır. Kıyaslama neticesinde yapay sinir ağları daha üstün performans sergilemiştir.

Ateşoğlu (2015), çalışmasında doğrusal olmayan bir yöntem olan yapay sinir ağları ve doğrusal bir yöntem olan ARIMA zaman serileri verilerindeki karmaşık olan

davranışları belirleyebilmek için uygulanmıştır. Çalışmada, ARIMA ve yapay sinir ağları ilk olarak birbirinden bağımsız edilmiştir. Daha sonra, ARIMA ve yapay sinir ağlarını birleştiren melez bir yöntem aynı veri setleri üzerinde test edilmiştir. Test edilen veri seti üzerinde ARIMA, yapay sinir ağı ve melez yaklaşımın performansları kıyaslandığında melez model performansının daha iyi sonuçlar verdiği tespit edilmiştir.

Karahan (2015), çalışmasında ARIMA ve yapay sinir ağları metotlarını karşılaştırarak, yapay sinir ağları modelinin ARIMA modeline nazaran daha iyi sonuç verdiğini tespit etmiş ve yapay sinir ağları modeli ile net ihracat miktarlarının tahminini çalışmışlardır.

Ekmekçi (2016), enerjinin tüm küresel etkilerini göz önüne alarak 1970-2013 yılları arasındaki doğalgaz tüketiminin Türkiye'ye etkileri gerek sayısal olarak gerekse istatistiksel yöntemlerle analiz edilerek gelecekteki tüketim miktarları kısa ve uzun vadeli olmak üzere ARIMA modeli ile tahmin etmiştir. Çalışma neticesinde, çimento sektörü dışında tüm sektörlerin istatistiksel olarak kısa vadeli tahmin edilebileceği ortaya konulmuştur. ARIMA modelleri vasıtasıyla 2013-2025 yılları arasındaki tahmini doğalgaz tüketim verileri analiz edildiğinde 2025 yılına dek "Birincil Enerji Arzı"nın artan bir trende sahip olduğu görülürken, tüketim oranında da artış olacağını öngörmüştür.

Wongsathan ve Seedadan (2016), çalışmalarında ARIMA ve yapay sinir ağları modelleri ile Tayland'da bulunan bir şehir için partiküler madde (PM-10) hava kirliliği tahmini çalışmışlardır. Tahmin çalışması için 2011-2014 yılları arasındaki veriler kullanılmıştır. Çalışma neticesinde iki model ile birlikte oluşturulan hibrit modelin daha iyi performans sunduğu saptanmıştır.

Kiki (2018), 2012-2015 yılları arasındaki verilerden faydalanılarak belirtilen yıllar arası en soğuk, en sıcak ve en yağışlı dönemler tahmin etmeye çalışmıştır. Türkiye elektrik piyasası gün sonrası fiyat tahminini belirlemek üzere yapay sinir ağları ile farklı modeller kurulup test edilerek hata oranları tespit edilmiştir. Tespit edilen hata oranları değerlendirilerek performans kıyaslanması yapılmıştır.

Wang, Li ve Li (2018), Çin Halk Cumhuriyeti'nin petrol tüketim verilerini incelemiştir. Bu veriler yardımıyla 2017-2030 yılları için ARIMA modeli yardımıyla

tüketim tahmini yapılmıştır. Tahmin sonuçları neticesinde önerilerde bulunan yazarlar gerekli mercilere petrol konusunda çeşitli uyarı ve önerilerde bulunmuşlardır.

Kılıç, Akkaya ve Memili (2018), çalışmalarında bir üniversitenin yemekhanesinden alınan veriler ile yemek talep tahmin modeli oluşturarak israfı önlemeyi hedeflemişlerdir. Çeşitli analiz metotlarının kullanımı ile günlük talep miktarları tahmin edilmeye çalışılmış ve performansı en yüksek olan yapay sinir ağları modeli olmuştur.

Şahin (2018), kripto bir para birimi olan Bitcoin'i incelemiştir. Bitcoin'in gelecekteki muhtemel değerleri için, yapay sinir ağları ve ARIMA metodundan faydalanarak tahmin çalışması gerçekleştirmiştir.

Ulucan (2018), konaklama işletmelerinde talep tahmini çalışması yapabilmek için yapay sinir ağları metodundan faydalanmıştır.

Musaylh, Deo, Adamowski ve Li (2018), çalışmalarında kısa dönemli elektrik talebini tahmin edebilmek için çeşitli metotların yanı sıra ARIMA modelinden de faydalanmıştır.

Ohyver ve Pudjihastuti (2018) orta kalitede olan pirinçlerin fiyat dalgalanmalarını tahmin edebilmek için ARIMA modellerinden faydalanmışlardır. ARIMA (1,1,2) tahmin çalışması için en uygun model olarak tespit edilmiştir.

Debnath ve Mourshed (2018), enerji planlama modellerinde tahmin metotlarını incelemişlerdir. Çalışmada yapay sinir ağları da dâhil olmak üzere çeşitli tahmin metotları incelenmiştir.

Anand ve Suganthi (2018), Hindistan'ın bir eyaletinde elektrik talep tahmini için çeşitli tahmin metotları ile birlikte yapay sinir ağlarından da faydalanarak talep tahmini gerçekleştirmişlerdir.

Amber ve Khan (2018), idari binalar için günlük elektrik tüketimini tahmin etmeye çalışmışlardır. Çalışmada Çoklu Regresyon, Genetik Programlama, Yapay Sinir Ağları, Derin Sinir Ağları ve Destek Vektör Makineleri tekniklerinin tahmin kabiliyetleri sınanmıştır. Tahmin çalışmasında Londra'da bulunan bir idari binaya ait 5 yıllık verilerden, 5 farklı parametre ışığında faydalanılmıştır. Bu parametreler; güneş ışını, sıcaklık, rüzgar hızı, nem ve çalışma günü olup olmadığı gibi kriterler ile 5 yıllık

veriler incelenmiştir. İlk 4 yıla ait veriler tahmin tekniklerini eğitmek için kullanılırken son 1 yıllık veriler ise tahmin değerlerinin doğruluğunu kıyaslamak için kullanılmıştır. Çalışma neticesinde Yapay Sinir Ağları %6 MAPE değeri ile en iyi sonucu sunarken, bu değerler Çoklu Regresyon için %8.5, Genetik Programlama için %8.7, Destek Vektör Makineleri için %9 ve Derin Sinir Ağları için ise %11 olarak elde edilmiştir.

Khaldi, Afia ve Chibeb (2019), yapay sinir ağları ve ARIMA dâhil olmak üzere, çeşitli tahmin metotları ile Fas'ta bir hastanenin acil departmanına tedavi için gelen insan sayılarını tahmin etmeye çalışmalardır.



3. PERAKENDECİLİK KAVRAMI

Bu bölümde perakendecilik ve perakende sektörü hakkında detaylı bilgiler verilerek, Türkiye’de ve Dünya’da genel kabul görmüş perakendecilik türleri hakkında bilgiler sunulacaktır.

3.1. Perakende ve Perakende Sektörü Tanımları

Farsça kökenli olan perakende kelimesi Türk Dil Kurumu tarafından; Maddi değeri mevcut varlıkların teker teker veya birkaç parça halinde satılması olarak tanımlanmaktadır (TDK, 2019). Paranın keşfi ile ilkel olarak başlayan perakende sektörü bugün ülkemizde toplam istihdamın yüzde 36,8’ini oluşturmaktadır (TÜİK, 2015).

En genel tanımıyla;” imal edilmiş ürün ve hizmetleri nihai tüketicilere pazarlayan kişi veya kurumların, nihai tüketicilere yönelik olarak gösterilen pazarlama faaliyetleri (Karafakıoğlu,2005)” şeklinde tanımlanmaktadır. Kotler’in perspektifinden” en son tüketiciye ve ticari kâr amacı gütmeyen kuruluşlara yapılan her türden mal ve hizmet satışı” şeklinde tanımlanmaktadır (Kotler,2000).

Yukarıdaki tanımlara ek ve paralel olarak kelime kökeni parçalara bölmek anlamında olan perakende, toptan satışın tam zıttı bir anlam ihtiva etmektedir. Bir mamulün veya mamulün yapım sürecindeki malzemelerin bölünerek satılması anlamına gelmektedir (Murat vd., 2013).

Bu yüzden perakendecilik, malların veya hizmetlerin bütün ekonomi prosesindeki nihai basamaktır. Daha kapsamlı bir tanımlama yapılırsa, tüketicilerin kişisel veya ailevi ihtiyaçlarını karşılayabilmek için gereken malları veya hizmetleri satın almak üzere gerçekleştirdikleri etkinliklerin tümüne perakendecilik denilmektedir (Berman ve Evans, 2001).

Perakendecilik sınırları içerisinde üreticiler tarafından tüketicilere ürün veya hizmetlerin sunulması hedefiyle aracılık konusu yer almaktadır. Ürün veya hizmetlerin ticari bir amaç güdülmeksizin yahut tekrar elden çıkarmamak şartıyla direk olarak tüketiciye pazarlanması ile ilgili etkinliklerin tamamı perakendecilik kavramını meydana getirir (Tek,1984).

Perakendecilik, dünyadaki birçok ekonominin en önemli basamaklarından biridir. Bilhassa gıda ve tekstil-hazır giyim perakendecileri, global düzeyde Amerika'dan Çin'e dünyanın dört bucağına yayılmış ve binleri aşan satış noktalarıyla nihai tüketiciye ürünlerini ulaştırmaktadırlar. 1990'lı yıllardan bu yana özellikle gelişmiş ülkelerde büyük ölçekli perakende firmalarının sayısı giderek artış göstermiştir. Ayrıca üretim faaliyetlerinden vazgeçerek perakende sektörüne kayan birçok firma bulunmaktadır (Özgür, 2011).

Günümüzde ise perakendeci, imalatçının veya üreticinin ürünlerini satmaya hazır ve zorunlu bir satış birimi olmaktan sıyrılarak, imalatçıların veya üreticilerin perakendecinin teşhir ve satış imkânlarından yararlanabilmek amacıyla birbirleri ile rekabet etmek zorunda kaldıkları bir pazarlama birimi haline evrilmiştir (Şireli, 1975).

Perakendeciler, ürünlerin ve hizmetlerin nihai tüketiciye ulaşmasına aracı kişi veya kuruluşlardır. Perakendeciler, tüketicilere mal veya hizmet sunarak tüketicilerin talep ve ihtiyaçlarını karşılarken, aynı zamanda alışveriş deneyimi yaşatmayı hedef edinmiş araçlar olarak da tanımlanabilmektedir (Varinli ve Oyman, 2013).

Perakendecilik, mal veya hizmetlerin nihai tüketiciye, mal veya hizmeti kişisel ihtiyaçları için tüketen kişilere satılması etkinliklerini içine almaktadır. Ana çalışma alanı, ürünleri toptancıdan satın alarak, üzerlerine kar eklemek, küçük miktarlarda nihai tüketiciye satışını sağlamaktır. Toptancı yahut üreticiden nihai tüketiciye aracısız mal satışı meydana geldiğinde de perakendecilik etkinliği gerçekleşmiş olmaktadır (Aydın, 2013).

3.2. Perakendecilik Sektörünün Tarihsel Gelişimi

Coğrafi gelişmeler vasıtasıyla farklı coğrafyada yer alan farklı ürünler ile tanışmaya başlayan insanlar bu ürünleri satın alma eğiliminde bulunmaya başladılar. Bu eğilim ticaret ve üretimin gelişmesine katkıda bulunmuştur. İhtiyaç ve talep edilen ürünlerin alınabilmesi için belirli mekânlar (çarşı, pazar, dükkân vb.) meydana getirilmiştir. Avrupa'da feodal sistemin değişmesi ile şehirleşme önemli bir hal almış ve İngiltere'de bu gelişme kent Rönesans'ına sebebiyet vermiştir. Şehirler, yönetim ve savunma amaçlı geliştirilmişlerdi. Ancak, daha sonra ticaret etkinlikleri ağırlık

kazanmıştır. Derebeylik sistemi deęiřtikten sonra řehirler, vergiden kurtulabilmenin yollarını aramışlardır. Serbest kalabilen řehirlerde ticaretin düzgün işleyebilmesi için muhtelif teşkilatlar kurulmuştur. Bu teşkilatlar, lonca sistemine uzanan yola öncülük etmişlerdir (Davies ve Ward, 2002).

1950’li yıllarda Avrupa perakendesi, savaş malları stoklarının ve işgücü sıkıntısının yükselişte olduęu, savaşın yıkıp harap etmiş olduęu fabrikaların hüküm sürdüęü bir perakendecilik olarak isimlendirilmiştir (Dawson, 2000).

Perakendecilięin gelişiminde etkili olan nedenler ise şöyle ifade edilebilir: Durumsal nedenler: Nüfusun hızla artması, süratli kentleşme, banliyö hattı. Ekonomik nedenler: Milli gelirlerin artması, ürün çeşitlerinin artması, kitlesel pazarların meydana gelmesi, üretim yöntemlerindeki yenilikler, perakendecilik sektöründeki kızgın rekabet, pazarlama sistemlerinde gelişmeler. Teknolojik nedenler: Ulaşım ve özel ulaşım alanlarındaki yenilikler, depolama imkânlarında yenilikler, ambalaj sektöründeki yenilikler. Sosyal ve kültürel nedenler: Ekonomik olarak bağımlı olan nüfus seviyesinde azalış, kadın istihdamında artış, sosyal hayat için ayrılan zamanın artması. Bilimsel nedenler: İşletme biliminde meydana gelen yenilikler, yönetici yetiřtirmede gelinen başarılı nokta. Hukuksal nedenler: Büyük mağazacılıęın devlet tarafından desteklenmesi, gıda ürünlerin dağıtımı için gerekli olan saęlık denetimlerinin artması ile barkod sisteminde gerçekleştirilen ilerleme ve yeniliklerin görülmesidir. (İslamoęlu, 2013).

Geçmiş zamanlardan bu yana birçok ürün ya seyyar olarak seyyar satıcılar vasıtasıyla ya da Pazar yerlerinde pazarcılar vasıtasıyla satışa sunulmuştur. 16. ve 17. yüzyıllarda Çin’de birtakım perakende zincirlerinin varlıęı bilinmektedir. Hudson’s Bay Company 1670 yılında Kanada’da zincir mağazalarını kurmuştur. New York’ta ise 1859 senesinde Atlantic & Pasific Tea Company řirketi modern zincir mağazalarının öncüsü olarak faaliyetlerine başlamıştır. 17. yüzyılda 1800’lü yılların ortasında Bon Marche’si Paris’te farklı birimleri bünyesinde barındıran bir mağaza halini almıştır. 19. yüzyılın ortasından sonra modern perakendecilik gelişmeye başlamış olup departmanlı mağazalar meydana gelmeye başlamıştır (Özdemir, 1999).

O dönemlerde ürünler büyük sergi alanında teşhir ediliyor, toptan satışların fiyatları düşük tutuluyordu. Amerika Birleşik Devletleri’nde 1930’larda hizmete giren süpermarketler 1950’li yıllarda gelişim göstermiştir. İçinde birden çok dükkânı

barındıran mağazalar şehir merkezlerinde faaliyete geçtikten sonra trafik yoğunluğu sebebiyle müşterilerin ilgisini kaybetmeye başlamıştır. Avrupa için de durum benzerlik gösteriyordu. Büyük ölçekte dağıtım olayında ilk Fransa göze çarpmaktadır. Perakende sektörünün globalleşmesinden sonra Almanya da önemli bir gelişim göstermiştir. Perakende sektöründe en yüksek ciroya sahip olan ülke ise 1980'lerin İngiltere'si olmuştur (Arasta, 1999).

Gıda dışındaki sektörlerde ilginin artması sebebiyle perakende işletme sayıları da buna mukabil artmıştır. Bu artışlar küreselleşmenin etkisiyle artan bir ivme yakalamıştır. Ticarete sınırların ortadan kalkması neticesinde yabancı yatırımlarla ortaklık, şirket evlilikleri gibi uygulamalar perakende sektörünün artan ivmesinde önemli bir rol oynamıştır (Cengiz ve Özden, 2003).

3.3. Perakende Satış Kanalları

Perakende satış kanalları örgütsel yapı ve yöntemlerine göre geleneksel ve modern perakendecilik olarak sınıflandırılabilir. Geleneksel perakendecilik binlerce yıllık geçmişten günümüze ulaşan yapı ve yöntemleri kapsar. Günümüzde geleneksel perakendecilik örnekleri; esnaf niteliğinde, aile işletmeleri şeklinde yönetilen, kurumsallaşmamış, kendi bulunduğu çevreye hizmet veren, bakkal, tuhafiyeci, kasap, manav formatındaki perakendecilerdir. Modern (organize) perakendeciler, büyük mağaza yapısına sahip, yüksek cirolara ulaşabilen, içerisinde birden çok mağaza barındırabilen süpermarket, hipermarket, zincir mağazalar, indirim mağazaları ve alışveriş merkezleri gibi kurumsallaşmış yapılardır (Tek, 2001).

Perakendeciler tüketicilerin talep düzeyine, tüketicilere sunulan hizmete, işletmenin konumuna ve çeşitli ölçütlere göre sınıflandırılabilir. İşlemlerin yapıldığı yer açısından perakendeciler dükkânlı ve dükkânsız olarak da sınıflandırılabilir (Mucuk, 2012).

3.3.1. Mağazalı perakendecilik

Kapalı mekânlarda gerçekleşen bu perakendecilik tipinde aktif satış işlemleri gerçekleştirilmektedir. Bu ortamda gerçekleşen perakendecilikte, müşteri ürünü yakından görme ve inceleme şansına sahiptir. Mağazalı perakendecilik çeşitli alt başlıklara ayrılmaktadır (Tek ve Demirci Orel, 2006).

3.3.1.1. Gıda perakendecileri

Gıda perakendeciliği, yoğun rekabet sebebiyle yeniliklere ayak uydurmaktadır. Geçmiş zamanlarda tüketiciler ihtiyaçlarını süpermarketler vasıtasıyla karşılarken günümüzde farklı perakendecilerden ihtiyaçlar karşılanmaktadır (Kotler ve Armstrong, 2006). Ağırlıklı gıda ürünleri sunan bakkal, market, süpermarket, hipermarket ve zincir market gibi işletmelerden meydana gelen gıda perakendeciliğinin son yıllarda gelişimi incelendiğinde, genellikle küçük ölçekli perakendeciliğin pazardaki payının azaldığı görülmektedir. Küçük ölçekli perakendecilerin, büyük ölçekli marketlerle fiyat ve ürün çeşitliliği sebebiyle rekabet etmekte zorlanmaktadır. Bu sektörde yaşanan yoğun rekabet sebebiyle küçük ölçekli perakendeciler de piyasada ki pazar paylarını korumak için satış kanallarını yeniden yapılandırmaktadır. Ayrıca büyük ölçekli olan hipermarket ve zincir marketler arasında da yoğun bir rekabet vardır (Serpil vd., 1998).

3.3.1.2. Genel ürün perakendecileri

Bu perakendecilik türünün örnekleri; özellikle mağazalar, bölümlü mağazalar, eczane zincirleri, kategori öldüren mağazalar, indirim mağazaları ve indirimli marka mağazalarıdır (Kurşunoğlu, 2009).

Özellikli mağazalar; belirli bir mamul hattına veya belirli bir pazara hizmet sunan ve bir uzmanlaşma dalında müşterisine çok çeşit sunabilen perakendecilerdir. Bu perakendecilerde uzmanlaşma büyük önem arz etmektedir. Belirli bir ürün çeşit yelpazesinde hizmet verirler. Binicilik kıyafeti ya da müzik sistemleri satan perakendeciler örnek verilebilir (Kurşunoğlu, 2009).

Bölümlü mağazalar; genel olarak gıda ürünleri harici tüketim mallarını, tek katlı geniş ya da çok katlı ve çoğunlukla her katı ayrı reyonlar şeklide çalışan büyük yapılarda hizmete sunan büyük perakendeci kuruluşlardır (Tek, 1984).

Eczane zincirleri; çoğunlukla sağlık ve kişisel bakım ürünlerinin satışa sunulduğu uzman mağazalarıdır (Kurşunoğlu, 2009).

Kategori öldüren mağazalar; ismini pazarlama stratejilerinden alan bu mağaza çeşitleri, tek bir kategoride, çok uygun fiyatlarla, çok geniş miktarda ürün sunarlar (Dunne ve Lusch, 1999)

İndirim mağazaları; bol ürün çeşidi, sınırlı servis ve makul fiyat sunan perakendecilerdir. Bu mağazalar kendi markaları ile veya üretici markaları ile ürünleri müşterisine sunabilmektedir (Lewy ve Weitz, 2007).

İndirimli marka mağazaları; markalı ürünleri makul fiyatlara satan perakendecilerdir. Bu gruba fabrika mağazaları ve tasfiye mağazaları örnek olarak verilebilir (Tek ve Orel, 2006).

3.3.1.3. Hipermarketler

Self servis tipinde faaliyet gösteren, envai çeşit gıda ve gıda harici ürünleri düşük fiyatlarla satan asgari 2500 m2 satış alanı ve otoparkı mevcut geniş bölümlü perakende satış mağazalarıdır (Tek, 1999). Ayrıca çok sayıda yazar kasa ve ödeme noktalarının bulunduğu, tüketicilerin çoğu gereksinimlerini tek bir mağazadan karşılama amacı ile kurulmuş dev alışveriş mekânlarıdır (Kaya, 2009).

3.3.1.4. Alışveriş merkezleri

Önemli bir kısmı Amerika Birleşik Devletleri'nde "MALL" olarak adlandırılmaktadır. Osmanlı döneminden günümüze kalan tarihi kapalı çarşıdan esinlenmişleridir. Tek bölmeli bir plan ile oluşturulmuş, yan yana mevcut olan küçük ve büyük perakendeci firmaların dükkân kiralararak oluşturdukları yapıdır. Bu karmaşık yapı içerisinde; lokanta, süpermarket, eczane gibi işletmeleri barındırmaktadır (Tek, 1999). Satış alanı

300.000 m²'ye kadar varan içinde otoparkı mevcut tek büyük bir bina içinde meydana gelen bu yapılar ortak, merkezi bir yönetime sahiptir (Çakmak, 2012).

3.3.1.5. İndirim mağazaları

Self servis sistemiyle hizmet veren, bilinen markaların ürünlerini devamlı düşük fiyatla müşterilerine sunmayı hedef olarak belirlemiş perakendecilerdir. Mevsimlik veya diğer indirim tiplerinden farkı, devamlı bir şekilde alışılmış fiyatların veya liste fiyatlarının altında fiyatlarla müşterilerine sunmasıdır (Mucuk, 2001).

Türkiye'de indirim mağazaları; tasarımsal olarak sade, ürünlerin koliler ile teşhir edildiği, mağaza büyüklüğünün 500 m²'ye kadar olduğu, mağaza konumlarının kiraların düşük olduğu ara sokaklarda yer aldığı mağazalardır (Pamir, 2012).

3.3.1.6. Süpermarketler

Süpermarketler ana olarak gıda maddeleri olmak üzere, temizlik ürünleri, kozmetik tarzı ürünleri açık vitrinlerde teşhir edildiği, self servis sistemi ile satış yapan bölümlü mağazalardır. Yüksek stok devir hızına sahip olan bu mağazalar, ürünleri düşük fiyatlarla tüketicilere sunmaktadır (Mucuk, 2012).

3.3.2. Mağazasız perakendecilik

Dükkânsız perakendecilik olarak da isimlendirilen mağazasız perakendecilik, müşterinin somut bir mağaza ya da dükkânı ziyaret etmeden yaptıkları alışveriş olarak tanımlanabilmektedir. Mağazasız perakendecilik genellikle telefon ve internet vasıtasıyla gerçekleşmektedir. Ayrıca, mağazasız perakendecilik büyük bir zaman tasarrufu sunması en geleneksel mağazacılığa karşı en büyük avantajıdır. Mağazasız perakendecilik aşağıdaki başlıklar altında incelenebilmektedir.

3.3.2.1. Katalog ve doğrudan posta perakendeciliği

Katalog veya broşür hazırlandıktan sonra ürün bilgilerini müşteriye elektronik posta veya mektup vasıtası ile müşterilerin alışveriş yapması hedeflenmektedir. Bu tip perakendecilerin en önemli örnekleri Avon Kozmetik veya İKEA olarak tanımlanmaktadır (Kotler ve Keller, 2009).

3.3.2.2 Doğrudan satış

Bir kuruma bağlı olarak bir satış uzmanının direkt olarak sahada, müşterinin bulunduğu konumda ziyareti ve birebir iletişimi ile ürünün tanıtılıp satışının gerçekleştirilmesi doğrudan satış tipi bir perakendeciliğe örnektir (Lewy vd., 2004).

3.3.2.3. Doğrudan pazarlama

Doğrudan pazarlama, ulaşılmak istenen tüketiciler ile direkti seri ve ölçülebilir tüketici geri bildirimleri almak ve sürdürülebilir müşteri ilişkileri sağlamak amacıyla titiz ve direkt ilişkiler kurmaktır (Kotler ve Armstrong, 2006). Bu tip pazarlama yöntemlerine örnek; katalog, doğrudan posta, televizyonlu alışveriş, tele pazarlama ve elektronik alışveriştir (Kurşunoğlu, 2009).

3.3.2.4. İnternet perakendeciliği

Tüketicinin 24 saat boyunca kesintisiz olarak evinden, işyerinden veya bulunduğu herhangi bir yerden bilgisayar, tablet veya telefon vasıtasıyla internete erişim sağlayarak ürün veya hizmet satın alma sürecine internet perakendeciliği denilmektedir (Dündar vd., 2007).

Dünya çapında perakende satışlarının, elektronik ticaret de dâhil olmaz üzere 2017 yılı için 23.455 milyar dolar olarak gerçekleştiği tahmin edilmektedir. E-ticaret sektörü

her yıl, geleneksel(fiziksel) perakende sektöründen yaklaşık olarak %1'lik pay almaktadır. Bu ivme ile birlikte e-ticaret 2017 yılı sonunda toplam perakende sektörünün yaklaşık %10,1'ini oluşturacaktır. 2011 yılında %3,6'lık hacme sahip olduğu bilinen e-ticaretin 2017 yılında ulaşacağı hacim, e-ticaretin büyüme ivmesini tahayyül edebilmemize yardımcı olacaktır (KPGM, 2018).

Günümüzde perakende sektörü, farklılaşan tüketici isteklerine karşı, zamanında ve doğru bir şekilde karşılık verebilmek için hızlı olmak ve farklı satış kanallarını uyumlu bir şekilde yönetmek zorundadır. Bu sebeplerden, günümüzde bilgi teknolojileri ve bu teknolojiler için gerekli alt yapılar büyük önem arz etmektedir. Teknolojik ilerlemeler, iletişimin çeşitlenmesi, tüketicilerin zaman darlığı sebepleriyle elektronik ticaret günden güne önem kazanmaktadır (Besfin, 2018).

3.4. Türkiye'de Perakende Sektörü

Türkiye perakende sektörünün yaklaşık %67'sini geleneksel perakende, %33'ünü ise organize perakende oluşturmaktadır. Organize diğer adıyla modern perakende özellikle son 15 senede pozitif bir ivme yakalamasına rağmen, geleneksel perakendecilik biçimlerinden olan esnaflık hala değerini korumaktadır. Bu bilgilere rağmen modern perakendecilik geleneksel perakendeciliği karşı pozitif ivmesini sürdürme eğilimindedir. Modern perakendeciliğin gelişmesinde etkili olan faktörler; Alışveriş Merkezlerine olan yatırımların artması, geleneksel perakendeciler için mevcut olan rekabet sorunu, tüketici davranış, talep ve alışkanlıklarında teknoloji sebebiyle yaşanan değişimler etkilidir. Kızgınlaşan rekabet sonucu, indirim marketlerinin agresif büyümesi, önemli buldukları mağazaları satın alarak veya devralarak ilerlemesi de geleneksel perakendecilik açısından olumsuz durum teşkil etmektedir (KPGM, 2018).

Osmanlı döneminde kapalı çarşılar, meyve&sebze hallerinin dışında seyyar perakendeciler de ciddi bir öneme sahipti. Kapalı Çarşı, Eminönü ve Tahtakale gibi geleneksel ticaret merkezlerinde yüzyıllardır süregelen ve geleneksel yöntemler ile esnaf ve zanaatkarlar hizmet vermektedir. Büyük şehirlerden satın aldıkları ürünleri küçük şehirlere veya köylere getirerek hizmet eden tüccarlar da oldukça fazlaydı. Bu

sebeplerden ötürü ticaret yollarının, güzergâhlarının üzerinde çok sayıda hanlar ve konaklama mekânları kurulmuştu (Varlı ve Özbay, 2011).

Orhan Gazi Bursa fethinin akabinde, günümüzde de faal olarak alışveriş merkezi görevi gören bedesteni kurmuştur. Fatih Sultan Mehmet İstanbul fethi akabinde ise 118 dükkân ve etrafında 984 ticarethane barındıran Kapalı Çarşı'yı inşa etmiştir. Osmanlı döneminde bedestenler, çarşılar ve esnaf işletmeleri perakende sektörünün en önemli bileşenleriydi (Aydın, 2013).

3.5. Dünya'da ve Türkiye'de Tüketici Eğilimleri

Globalleşen dünya neticesinde diğer sektörlerde olduğu gibi perakende sektörü de müşteri merkezli politikalar ile yönetilmektedir. Müşteri talep, ihtiyaç ve davranışlarını merkeze alan bu politika coğrafya ve demografiden bağımsız olarak dünyada genel-geçer bir politika halini almıştır. Bu sebeple dünya genelinde perakende sektöründe faaliyet gösteren firmalar, müşterinin talep, ihtiyaç ve davranışları ile ilgili olarak birbirine benzer etkiler ve bunlardan doğan sebepler ile mücadele etmektedir. Dünya genelinde sektör için başlıca sorunlardan birisi, müşteri davranış ve taleplerinin değişmiş olmasıdır. Satış kanallarında ulaşılan çeşitlilik neticesinde müşteriler, envai çeşit bilgi ve alışveriş imkânına sahiptir. Bu nedenle tek satış kanalından faaliyetlerini sürdüren perakende firmaları yoğun rekabetin tehdit ve baskısı altındadır. Online alışveriş ve türevleri olan mobil alışveriş ve sosyal alışverişin gelişmesiyle birlikte, yıllardır süregelen fiziksel mağazacılık cirolarında önemli kayıplar yaşamaktadır. Bu kayıpların farkında olan firmalar satış kanallarını artırma yoluna giderek bu değişimlere ayak uydurmaya çalışmaktadır. Diğer yandan teknoloji ve dijitalleşme ile birlikte tüketici verileri çok büyük miktarlara ulaşmaktadır. Bu veriler gelişen veritabanı sistemleri ile birlikte analiz edilerek firmalara sunulmakta ve firmalar bu bilgiler ışığında müşteri merkezli adımlar atmaktadır. Perakende sektöründe gittikçe kızışan rekabet sonucu gelen değişimler, tüm sektör oyuncularını bu değişime ayak uydurmaya zorlamıştır. Rekabete, değişime ayak uyduramayan firmaların ya büyük kayıplar verdiği ya da piyasadan silindiğine tanıklık edilmiştir. Şüphesiz bu durum en çok tüketici yararına olmuştur. Geleneksel yöntemlere göre çok


daha kısa zamanda, iyi ve kaliteli çok seçenekli hizmete ulaşan müşteriler son dönemlerde artık kişiye özel hizmet talep etmektedir (KPGM, 2018).

3.6. Hanehalkı Tüketim Harcamaları

TÜİK tarafından yayımlanan 2015 ve 2016 yılı hane halkı tüketim harcamaları incelendiğinde, ülkemiz genelinde yapılan tüketim harcamalarında en büyük pay konut ve kira harcamalarına ait olmaktadır. İkinci sırada ise gıda ve alkolsüz içecekler yer almaktadır. Kalan yüzdeler aşağıda verilen bilgilerle izah edilmiştir.

Tablo 3.1. Hanehalkı tüketim harcamalarının türlerine göre dağılım tablosu, Türkiye, 2015-2016(TÜİK, 2016)

HANEHALKI TÜKETİM HARCAMASI	2015	2016
GIDA VE ALKOLSÜZ İÇECEKLER	20,2%	19,5%
ALKOLLÜ İÇECEKLER, SİGARA VE TÜTÜN	4,2%	4,4%
GİYİM VE AYAKKABI	5,2%	5,2%
KONUT VE KİRA	26,0%	25,2%
MOBİLYA, EV ALETLERİ VE EV BAKIM HİZMETLERİ	6,1%	6,3%
SAĞLIK	2,0%	2,0%
ULAŞTIRMA	17,0%	18,2%
HABERLEŞME	3,7%	3,7%
EĞLENCE VE KÜLTÜR	2,9%	2,8%
EĞİTİM HİZMETLERİ	2,2%	2,3%
LOKANTA VE OTELLER	6,4%	6,4%
ÇEŞİTLİ HİZMETLER	4,3%	4,2%



Şekil 3.1.Hanehalkı tüketim harcamaları grafiği

4. TALEP TAHMİN YÖNTEMLERİ

Bu bölümde talep tahmin yöntemlerinden ve öneminden detaylı olarak bahsedilecektir.

4.1. Talep Tahminin Önemi

Günümüzde meydana gelen sert rekabet ortam ile birlikte, kurumlar doğru adımlar atabilmek için gelecek planlamasına ihtiyaç duymaktadır. Rekabetçi piyasa, ekonomik ve politik dalgalanmalar neticesinde geleceği öngörebilme zorlaşmakta bu sebeple doğru öngörmenin önemi artmaktadır. Bu sebeplerden ötürü birçok kurum ve araştırmacı tahmin hakkında araştırmalar gerçekleştirmektedirler (Şen ve Kaba, 2009). Tahmin yöntemleri günümüzde çağrı merkezinde çalışacak kişi sayısının öngörülmesinden, faiz oranlarının belirlenmesine kadar geniş bir alanda kullanılmaktadır (Hanke ve Wichern, 2009).

4.2. Talep Tahmininin Sınıflandırılması

Talep tahminleri sürece veya nesneye bağlı olarak mikro veya makro tahmin şeklinde iki genel başlık altında incelenebilir. Bu başlıklara örnek olarak; üretim yapan bir firmada bir müdürün belirli zaman aralıklarıyla çalışacak kişi sayısını tahmin ederek işgücü planlaması yapması mikro, bir ülkede gelecek dönemler için çalışacak kişi sayısının hükümet tarafından tahmin edilmesi ise makro tahmin sınıfına girmektedir (Hanke ve Wichern, 2012).

Tahmin için bir diğer sınıflandırma ise tahmin sonucunun durumuna göre yapılan sınıflandırmadır. Bu sınıflandırmada tahmin sonucu üç şekilde düşünülebilmektedir. Nokta tahmin ile tahmin süreci sonunda tek bir çıktıya ulaşılır. Aralık tahmini ile belirli güven aralıklarındaki değerlere ulaşılır. Son olarak olasılık dağılımı tahmin edilerek yoğunluk tahminine ulaşılmış olunur (Hanke ve Wichern, 2012).

Talep tahmin yöntemleri nitel ve nicel olması bakımından iki farklı sınıf altında incelenebilmektedir. Makridakis ve diğ. (1998) sınıflandırmayı şu şekilde ele almışlardır:

Nicel Yöntemler: Sayısal bilgilerin yetersiz kaldığı durumlarda nicel yöntemler vasıtasıyla tahmin yapılabilmektedir. . Bu yöntemlerin başarıyla uygulanabilmesi için üç şarta ihtiyaç vardır. Bunlar;

- Geçmişle ilgili bilginin mevcut olması,
- Mevcut olan bu bilgilerin nümerik olarak şekillendirilebilmesi,
- Geçmişe ait olan desenlerin bazı yönlerden gelecekte de devam edebilmesidir.

Nicel yöntemler ise kendi içerisinde ikiye ayrılır:

- Zaman serisi: Geçmişte oluşan talep tahminlerinden faydalanılarak gelecekteki durumlar için talep tahmin edilir. Mevcut verilerin çok fazla değişim göstermediği durumlar için uygundur.
- Nedensel: Çevredeki faktörlerin talebi nasıl etkilediğini bulur. Talebi etkileyen sebepler tespit edilmesinin akabinde talep tahmin modeli kurulur ve etkileyen sebeplerin etki derecesi bulunur.

Nitel Yöntemler: Nitel yöntemler ise mevcut verilerin yeterli olmadığı durumlarda tercih edilir. Genellikle uzman görüşleri yardımıyla tahmin çalışması yapılır.

4.3. İstatistiksel Yöntemlerle Talep Tahmini

İstatistiksel yöntemler yardımıyla, geçmişteki talep verileri ile talebi etkileyen sebepleri ekonomik göstere ilişkilerine göre analiz ederek talep tahmini yapılmaktadır. Bu yöntemler yardımıyla geçmiş olaylar incelenerek gelecek dönemler için gerekli planlar oluşturulabilmektedir. Talep öngörülmesinde yaygın olarak kullanılan istatistiksel yöntemlerden bir kısmı; regresyon analizi, eğri uyurma

yöntemi, zaman serileri analizi yöntemi, hareketli ortalamalar yöntemleridir (Karahan, 2009; Tekin, 2009).

Günümüzde, talebi etkileyen etkenlerin çok olması ve bunların birbirleriyle ilişkilerinin karmaşık olması sebebiyle, tecrübe ve sezgi ile yapılan tahminler yetersiz kalmaktadır. Bu sebeple istatistiksel yöntemlerle talep tahmini büyük önem arz etmektedir. Talep tahmin yöntemlerinde kullanılan teknikler, uygulamalı istatistiğin konuları içerisinde yer almaktadır (Kobu, 1994).

Tahmin işlemlerini gerçekleştirebilmek için mevcut birçok model bulunmaktadır. Bu modeller sayısal tahmin modelleri ve sayısal olmayan tahmin modelleri olmak üzere iki başlık altında incelenebilmektedir. Geçmişe dönük yeterli veri elde edilememesi durumunda, kişisel yargı, deneyim, gözlem ve tecrübeye dayalı olarak tahmin yapılabilmektedir. Sayısal modellerde ise tahmin yapılırken geçmişe dönük verilerden faydalanılmaktadır. Tüm sayısal teknikler için geçmişe dönük doğru ve yeterli bilgi elde edilmesi gerekmektedir. Yetersiz ve doğruluk derecesi yüksek olmayan veriler ile hangi tahmin modeli olursa olsun, iyi ve güvenilir sonuçlar almak mümkün değildir. Sayısal tahmin yöntemlerinin bir kısmı son derece basit iken, bir kısmı da fazlasıyla karmaşık yöntemlerdir. Bir genelleme yapmak mümkün olmasa da bazı modellerin diğer modellerden iyi sonuçlar verildiği görülmektedir. Farklı yapı ve durumdaki tahminler için farklı yöntemler uygulanmalıdır (Üreten, 2005).

4.3.1. Regresyon analizi yöntemi

Regresyon analizi, herhangi bir değişkenin (bağımlı değişken) bir veya birden fazla değişken ile (bağımsız veya açıklayıcı değişken) arasındaki ilişkinin matematiksel bir fonksiyon olarak yazılmasıdır. Yazılan bu fonksiyon regresyon denklemi olarak isimlendirilmektedir. Regresyon denklemi yardımıyla bağımlı değişken ile bağımsız değişkenler arasındaki ilişkiyi kuran parametrelerin değerleri tahmin edilmektedir. Bağımlı değişkeni etkileyen bağımsız değişkenlerin tahmin edilmesi, bu değişken üzerinde geliştirilecek plan ve politikalarda hangi değişkenlerin önem kazandığının belirlenmesine yardımcı olmaktadır (Çağlar, 2007).

Regresyon analizi yöntemi ile hangi etkenlerde nasıl bir deęişiklik yapılırsa, ilgilenilen deęişkende artış veya azalış meydana geleceęi meydana çıkarılabilmektedir. Yeterli seviyede açıklayıcı gücü olan güvenilir bir regresyon katsayısı yardımı ile güvenilir tahminler yapabilmek mümkündür. Regresyon analizinde, eşitlik (formül) dönemseller olarak deęişim gösteren geçmiş verilerin kullanımıyla geliştirilebilmektedir. Tahmin modelinde bağımsız deęişkenlerindeki değerleri büyük oranda sıra dışı değerler olması durumunda, tahmin hatası da buna paralel olarak artış gösterecektir. Geçmiş verilerin düzenli ve sürekli olduđu durumlarda ise tahminin tutarlılığı da o oranda yüksek olacaktır (Ballot, 1986).

4.3.2. Korelasyon yöntemi

Regresyon denklemi, bağımsız deęişkenlerde meydana gelecek deęişiklik durumlarında, bağımlı deęişkenin sahip olacağı değerleri göstermektedir. Korelasyon yöntemi ise, iki deęişken arasında olan ilişkinin derecesini, doğruluk düzeyini ölçen bir kavramdır. Dięer bir tanımla, ilişkinin denklem tarafından hangi düzeyde tanımlandığını ifade eder. Deęişkenler arasındaki ilişki güçlendikçe oluşturulacak tahmin modellerinin de doğruluğun o derecede artması beklenmektedir (Üreten, 2005).

4.3.3. Basit ortalamalar yöntemi

Basit ortalamalar yöntemi, bir seriye ait verilerin toplamının, fiili gözlem sayısına bölünmesi ile elde edilir. Geçmişe ait verilerin, genel olarak bir artış veya azalış eğilimi göstermedięi yahut gelecek için büyük çapta bir deęişikliğin beklenmedięi tahmin çalışmalarında bu yöntem uygulanabilmektedir. Lakin ilerleyen dönemlerde artış veya azalış eğilimi gözlemlendięi koşullarda gerçekleşen talep, tahmin edilen talep ile aynı yönlü giderek artan sapmalar gözlemlenecektir (Kobu, 1994).

4.3.4. Son dönem talebi yöntemi

Son dönem talebi yönteminin temel mekanizması; bir önceki dönemde meydana gelen talebin, gelecek dönemde meydana gelecek talebin tahmini olarak uygulanmasıdır. Bu yöntemin işleyişinde uzun, karışık hesaplamalara ihtiyaç yoktur. Geçmişe ilişkin veriler, ortalama bir değer etrafında sürekliliği sahip ve çok değişim eğilimi göstermiyorsa uygulanabilmektedir (Tanyaş ve Baskak, 2008).

4.3.5. Hareketli ortalamalar yöntemi

Hareketli ortalamalar yönteminin ayırt edici özelliği, mevsimsel etkilerin talep üzerinde oluşturdukları etkilerini net bir biçimde sunması ve çok eski dönemlere ait geçmiş verileri dikkate almamasıdır. Hareketli ortalamalar yöntemi ile yapılan tahminlerde istenilen sonuçlara ulaşabilmek için aylık gerçekleşen satışların, önceki veya yakın dönemdeki ayların etkisinde olması gerekmektedir (Tanyaş ve Baskak, 2008). Hareketli ortalamalar yöntemi ile uzak geçmişe nazaran yakın geçmiş talep verilerin kullanılarak yalnızca bir dönem için satış tahmini yapılabilmektedir (Karahana, 2011).

4.3.6. Ağırlıklı ortalama yöntemi

Ağırlıklı ortalama yöntemi, belirli döneme ait verilerin, en yakın döneme ait olan veriler, gelecek periyotlar için kesin fikirler verdiği durumlarda bu yöntemden faydalanılabilmektedir. Bu yöntemin temel felsefesi, geçmişe ait olan verilerin ortalama üzerindeki etkisinin farklı olmasıdır. Bu sebeple, eğilim durumu ve diğer etkenlerin etkisi ortalama olarak ortadan kalkmalıdır. Bu yöntem için, tüm dönemler ilk dönemden itibaren hesaba katılmaktadır (Tanyaş ve Baskak, 2008).

4.3.7. Ağırlıklı hareketli ortalama yöntemi

Ağırlıklı hareketli ortalama yönteminde de dönemlere belli bir ağırlık verilmektedir. Fakat bu yöntemde geçmişe ait tüm veriler kullanılmamaktadır. Bu yöntemde tahmin yapabilmek için belirli sayıda en yakın dönem değerleri hesaba katılmaktadır. Bu yöntemin çözümlenmesinde, yakın zamana ait olan dönemlere daha fazla ağırlık verilmektedir. Hesaba katılacak dönem sayısı ve ağırlıkların değişmesi durumunda tahmin değerleri de değişim gösterecektir (Tanyaş ve Baskak, 2008).

4.3.8. Üssel düzeltme yöntemi

Üssel düzeltme yöntemi uygulanırken, ağırlıklı ortalama sistematiğini dikkate almaktadır. Bu tahmin yöntemi, geçmiş döneme ait verilere eşit ağırlık vermesi bakımından basit hareketli ortalamalar yöntemine benzerken, geçmiş döneme ait verilere eşit olmayan, farklı ağırlıkların tayin edildiği yöntemler kümesidir. Üssel terimi, verilerin eskimesiyle verilen ağırlıkların üssel bir şekilde azalması anlamına gelmektedir. Başka bir ifade ile tahmin yapılırken faydalanılan geçmiş döneme ait verilerden yakın geçmişte meydana gelenlere yüksek üssel değerlerin tayin edilmesi, daha eski döneme ait olanlara düşük üssel değerler atanması anlamına gelmektedir (Çağlar, 2007). Üssel düzeltmenin sahip olduğu avantaj, geçmiş verilere gerek duymadan hesaplama kolaylığı sunmasıdır (Tanyaş ve Baskak, 2008).

4.3.9. Simülasyon (benzetim) yöntemiyle talep tahmini

Simülasyon kelimesi, en geniş anlamıyla “gerçek sistemin işleyen bir modeli” demektir. Simülasyon, gerçek sistemi bulmaya çalışan bir analiz modeli olarak tasavvur edilebilir. Gerçek manada da kurulmuş bir simülasyon modeli, işlemeye başlamasıyla birlikte gerçek sisteme yaklaşılmaya başlamaktadır (Karahan, 2011).

Benzetim (simülasyon) çok esnek ve etkili bir yöntem olarak matematik modellerinin uygulanmadığı her koşulda uygulanabilen bir yöntemdir. Bu yöntemin

kullanılabilmesi için modelin ihtiyacı, sisteme ait davranışlar hakkında bilgidir. Ancak simülasyon yöntemi ile elde edilecek çözümlerin optimal olmadığı, yeterli sayıda tekrar ile optimum değere yaklaşılabileceği bilinmelidir (Kobu, 1994). Bir işletme probleminin analizi için kurulan bir model çeşitli karışıklar ihtiva edebilir. Bu gibi durumlarda benzetim önemli bir model kurma ve çözüme tekniği olarak uygulanmaktadır (Hakan, 1995). Bu model tipi, basit matematiğin yeterli gelmediği durumlarda problemlere yaklaşma olanağı sunmaktadır (Monks, 1996).

4.3.10. Zaman serileri analizine dayanan talep tahmin yöntemleri

Zaman serisi analizi, rastsal bir zaman sersinde düzensiz görünümde mevcut olan dalgalanma veya hareketlerin, sebeplerini tespit ederek zaman serisi bileşenlerine ayırmak, bunların ileride alacakları değerleri tahmin etmek ve bileşenleri sentezleyerek belirli bir tahmin değerine ulaşmak ile alakalıdır (Özmen vd., 2013). Zaman serileri analizleri vasıtasıyla ileriki dönemler için tahmin yapılırken, geçmişte mevcut olan hareketlerin gelecekte de aynı eğilimi sunacağı varsayılmaktadır (Özmen vd., 2013).

Zaman serileri analizi ile bir işletmeye ait geçmiş satışlar incelenerek, bu satışlara ait belirli bir eğilimin mevcut olup olmadığı tespit edilerek, geleceğe dönük talep tahminleri gerçekleştirilir (Karahana, 2011). Bu analiz yöntemi, geçmiş verilerin zamanla gösterdiği düzeni esas almaktadır. Bu yöntem geçmiş veriler yardımıyla geleceği tahmin etmeyi hedeflemektedir (Üreten, 2005). Başka bir tanım ile zaman serileri, bir değişkenin düzenli aralıklarla gözlemlenmesidir (Monks, 1996).

4.3.10.1. Zaman serilerini etkileyen etkenler

Zaman serilerinde meydana gelen dalgalanmaların dört sebepten kaynaklandığı varsayılmaktadır. Ayrıca bu dalgalanmalar ekonomik, sosyal ve psikolojik faktörlerinin birleşiminden meydana gelebilmektedir (Özmen vd., 2013). Bu dört etken sırasıyla:

T: Trend,

M: Mevsimsel Dalgalanmalar,

K: Konjonktürel Dalgalanmalar,

D: Düzensiz Dalgalanmalar olarak varsayılmaktadır (Ateşoğlu, 2015).

Trend (Ana Eğilim), bir zaman serisinin uzun bir periyot içerisinde belirli bir yöne doğru gösterdiği eğilim olarak adlandırılmaktadır. Mevsimsel dalgalanmalar ise, birbirini izleyen belirli zaman dilimlerinin (gün, ay, yıl) aynı zaman noktalarında artış veya azalış olarak gösterdikleri düzenli değişimlerdir (Özmen vd., 2013).

Konjonktürel dalgalanmalar, zaman serisinin trend doğrusu veya eğrisi etrafında meydana gelen uzun dönem dalgalanmalarıdır. Bu dalgalanmalar dönemsel değil, döngüsel dalgalanmalardır. Rastsal sebeplerle yahut geçici olarak meydana gelen dalgalanmalara ise düzensiz dalgalanmalar denmektedir (Özmen vd., 2013).

Zaman serisine ait gerçek gözlem değerleri (Y_t) ile yukarıda bahsi geçen etkenler arasındaki matematiksel ilişki:

$$Y_t = T_t + K_t + M_t + D_t \quad (4.1)$$

4.1 numaralı denklemde gösterildiği üzere toplamsal ilişki kurulabileceği lehinde görüşler mevcut olmakla birlikte, bu konuda genel kabul gören yaklaşım çarpımsal ilişkiyi uygulamak yönündedir. Çarpımsal ilişki:

$$Y_t = T_t * K_t * M_t * D_t \quad (4.2)$$

Zaman serilerine ait olan veriler stokastiktir. Başka bir anlamda, önceden öngörülmesi mümkün olmayan değerleri zamanın belli aralıklarında rastsal olarak alırlar (Gujarati, 2004). Zaman serilerinde, veriler zamana göre sıralıdır ve çoğunlukla ardışık gözlemler birbirlerine bağımlı durumdadır. Dönmeler arasında var olan bağımlılık sebebi ile güvenilir tahminler yapılabilmektedir (Vandaele, 1983).

Zaman serilerine ait diğler bir özellik, durağan ya da durağan olmamalarıdır. Değişkenler arasında makul ilişkiler var edilebilmesi için analizi yapılan seriler durağan olmalıdır (Tarı, 2010). Durağanlık için ihtiyaç duyulan şartların sağlanamadığı durumlarda, zaman serisi durağan olmayan olarak isimlendirilmektedir. Daha açık bir tanım ile zaman serilerinin sabit bir ortalama yakınlarında dağılmadığı yahut stokastik sürece ait özellikleri zamana bağılı olarak değişmesi ile durağan olmayan zaman serileri meydana gelir (Sevüktekin ve Nargeleçekenler, 2007). Gerçek dünyada mevcut olan zaman serileri genellikle durağan değildir. Zaman serilerinin uygun bir modele bütünleşebilmesi için ilk olarak serilerin durağan hale getirilmesi gerekmektedir (Kutlar, 2007).

Bir değişkenin durağan halde olup olmadığı yahut durağanlık derecesi tespit edilirken en genel kabul görmüş yöntem birim kök testidir (Gujarati, 2004). Dickey Fuller (DF) yaklaşımı ise, bu testlerde en yaygın olarak kullanılan yaklaşımlardan biridir. Dickey Fuller yaklaşımı; serinin birim köke sahip (durağan halde) boş hipotezine karşı, birim köke sahip olmadığı (durağan olduğu) alternatif hipotezine karşı sınama durumudur (Harr, 1995).

Zaman serileri ile tahmin yapılırken en fazla tercih edilen ve en kapsamlı olan istatistiksel yöntem Box-Jenkins modelleridir. Otoregresif (AR), Hareketli Ortalama (MA), Otoregresif Hareketli Ortalama (ARMA) ve Otoregresif Entegre Hareketli Ortalama (ARIMA), Box-Jenkins modellerini oluşturmaktadır. AR(p), MA(q) ve ARMA (p, q) modelleri durağan süreçler için uygulanırken, ARIMA (p, d, q) modeli ise durağan olmayan süreçler için uygulanmaktadır (Biçen, 2006).

4.3.10.2. Box-Jenkins yöntemi

Box-Jenkins yöntemi, kısa dönem tahminlerinde çok başarılı olup, tek değişkene sahip bir modeldir. Bu modelin kullanıldığı seride, eşit zaman aralıklarına sahip gözlem değerlerinden meydana gelen kesikli ve durağan bir seri olması, bu yöntemin önemli varsayımlarından biridir. Tekniğin hedefi, en az sayıda parametre içeren uygun modelleri elde etmektir. Diğer tekniklere nazaran anlaşılması zor ve karmaşık bir tekniktir. Bu yöntemden önce kullanımda olan Hareketli Ortalama ve Üssel Düzeltme

Teknikleri'nde tahmin deęerleri, bilgisayar programlarına mdahale etmeye gerek kalmadan otomatik bir Őekilde ulařılırken, Box-Jenkins teknięinde yapılan bu iřlem kısmen otomatik deęildir. Box-Jenkins ynteminin, zerinde alıřılan serilerin duraęan ya da duraęan olmaması, mevsimsel etkiye sahip olup olmaması gibi farklı senaryolar iin farklı tahmin modelleri geliřtirme yeteneęine sahiptir. Ayrıca bu yntem zaman serileri iin doęrusal filtreleme teknięi olarak da anılmaktadır (aęlar, 2007).

İleriye dnk tahminler zerine yoęunlařan George Box ve Gwilym Jenkins 1970 senesinde, Otoresif Entegre Hareketli Ortalama modelini literatre sunmuřlardır (Anderson, 2003). Bu sebepten tr ARIMA modeli Box- Jenkins yntemleri olarak da anılmaktadır. Son yıllarda bilgisayar uygulamalarındaki artıřa paralel olarak zaman serisi verilerinin kullanımı da artmakta ve bu yntemi ileriye dnk ngrlerde uygulayanların sayısı artıř gstermektedir (Bircan ve Karagz, 2003). ARIMA yntemi tek deęiřkene sahip kısa dnem tahminlerinde bařarılı bir Őekilde uygulanmakta ve gzlemlenen verilerin kesikli ve duraęan bir yapıya sahip olmaları gerekmektedir. Box-Jenkins modelleri 3 bařlık altında incelenebilmektedir (Box vd., 2016):

1. Duraęan doęrusal stokastik modeller (ARMA),
2. Duraęan olmayan doęrusal stokastik modeller (ARIMA),
3. Mevsimsel modeller (SARMA)'dır.

ARIMA modellerini oluřturabilmek iin Box-Jenkins metodolojisi řu ařamaları iermelidir (Manoj ve Madhu, 2012):

- 1.) Modelin tanımlanması,
- 2.) Parametre tahmini ve seim,
- 3.) Modelin doęrulanması,
- 4.) Modelin uygulanması ařamalarıdır.

Box-Jenkins Yntemi yardımıyla tahmin edilebilen Zaman Serisi Modelleri; Otoresif (AR) Modeli, Hareketli Ortalama (MA) Modeli, Otoresif-Hareketli Ortalama (ARMA) Modeli ve Otoresif Btnleřik Hareketli Ortalama (ARIMA) Modelidir (Kaynar ve Tařtan, 2009).

4.3.10.2.1. Otoregresif hareketli ortalamalar (AR-MA) yöntemi

Otoregresif (AR) sürecin dayanağı, zaman içinde verilerin değişim göstermeyeceği varsayımdır. Örnek olarak, bir ay için 100 birimlik satış var ise bu farkın kapatılması için 100 birin yerine koyulmalıdır. Süreç içerisinde fazla veya az satış olmaz ise süreç etkilenmez. Bu durum otoregresif süreç olarak isimlendirilir. Yöntemin Hareketli Ortalama (MA) süreci ise, serideki mevcut gecikmeli hata teriminin, şimdiki mevcut hata terimini etkileme durumu olarak tanımlanmaktadır (Adıyaman, 2007).

4.3.10.2.2. Otoregresif bütünleşik hareketli ortalamalar (ARIMA) yöntemi

Otoregresif Bütünleşik Hareketli Ortalamalar Yöntemi'nin temeli zaman serilerine dayanmakta olup, tek yahut çok değişkenli olabilmektedir. Talep tahmini çalışmaları için genellikle tek değişkenli Otoregresif Bütünleşik Hareketli Ortalamalar yöntemi tercih edilmektedir (Clark, 2002). Modelin ama işlevi otoregresif süreçleri bünyesinde barındırmasıdır. Daha açık ifade ile geçmiş verilerden faydalanarak gelecek dönemler için istatistiksel tahminler yapabilmesi, süreçleri bir araya toplayabilmesi ve Hareketli Ortalama süreçlerinin hepsini kapsamı olarak bilinmektedir (Chang, 2001). Box-Jenkins iki modeli sentezleyerek bu modeli geliştirmişlerdir. Zaman serilerinin durağan olmadığı durumlarda, zaman serilerinin bir veya birden çok kere fark alma işlemi uygulanmasıyla seri durağan hale getirilir (Adıyaman, 2007).

ARIMA modelleri, durağan olmayan fakat fark alma işlemi neticesinde durağan hale getirilmiş serilerde kullanılan modellerdir. İlk başta durağan olmayan lakin fark alma işlemi neticesinde durağan hale gelmiş serilere kullanılan modeller “durağan olmayan doğrusal stokastik modeller” şeklinde isimlendirilmektedir. Bu modeller d dereceden fark uygulanmış serilere kullanılan, değişkenin t-dönemine ait değerinin belirli bir sayıdaki geri dönem değerleri ile aynı döneme ait hata teriminin doğrusal bir fonksiyonu şeklinde belirtildiği AR dönemidir. Değişkenin t- dönemindeki değerinin mevcut dönemdeki hata terimi ve belirli sayıda geri dönem hata terimlerinin doğrusal fonksiyonu olarak belirtildiği MA modellerinin bir araya gelmesidir. Modellerin genel olarak ARIMA (p, d, q) şeklindedir. Burada belirtilen p ve q harfleri sırasıyla Otoregresif (AR) Modelin ve Hareketli Ortalama (MA) Modelinin derecesi, d ise fark alma derecesi anlamına gelmektedir (Kaynar ve Taştan, 2009).

$$Z_t = \Phi_1 Z_{t-1} + \Phi_2 Z_{t-2} + \dots + \Phi_p Z_{t-p} + \delta + a_t - \Theta_1 a_{t-1} - \Theta_2 a_{t-2} - \dots - \Theta_q a_{t-q} \quad (4.3)$$

4.3 nolu eşitlikte; $Z_t, Z_{t-1}, \dots, Z_{t-p}$ d dereceden farkı alınmış gözlem değerlerini, $\Phi_1, \Phi_2, \dots, \Phi_p$ d dereceden farkı alınmış gözlem değerleri için katsayıları, δ sabit değeri, $a_t, a_{t-1}, \dots, a_{t-q}$ hata terimlerini ve $\Theta_1, \Theta_2, \dots, \Theta_q$ hata terimleri ile ilgili katsayıları göstermektedir (Yükçü ve Gönen, 2009).

4.3.11. Yapay sinir ağları yöntemiyle talep tahmini

Yapay sinir ağları yöntemiyle talep tahminleri bir sonraki bölümde ayrıntılı olarak ele alınacaktır.

5. YAPAY SİNİR AĞLARI

Bu bölümde, uygulama kısmında kullanılacak olan, yapay sinir ağları hakkında detaylı bilgiler sunulacaktır.

5.1. Yapay Sinir Ağı Tanımları

Yapay sinir ağları (Artificial Neural Networks-ANN), insan beyninin çalışma prensibinden etkilenilerek, esinlenilerek geliştirilmiş, birbirleri ile paralel çalışan, bilgi alan ve bilgi gönderen bir yapıdan meydana gelmektedir. Problemleri çözme amacıyla faydalanılan iş elemanları (yapay sinir hücreleri), bir ağ şeklinde birbirlerine bağlanmıştır. Hücreler arasında gerçekleşen bilgi akışı, bağlantı değerleri ve ilişkilerle gösterilmektedir. Sistemin öğrenme kabiliyeti ve zeki davranışı, bağlantı değerlerinin vasıtasıyla sunulmaktadır (Tekin, 2009). Yapay sinir ağları, dışarıdan herhangi bir yardıma ihtiyaç duymadan, insan beyninin karakteristiklerinden olan, öğrenme yolu ile yeni bilgilerin çıkarımını yapabilme, yeni bilgiler oluşturabilme ve keşfedebilme gibi kabiliyetlere sahip bilgisayar sistemleridir (Öztemel, 2012).

Başka bir tanıma göre yapay sinir ağları, geleneksel modelleme tekniklerinden yapısal ve kavramsal olarak ciddi farklılıklar ihtiva eden bir modelleme yöntemidir. Bu model temelde, insan beyninin çalışmasını taklidiyle ortaya çıkmıştır. İnsan beyninin işleyişi ile alakalı nörofizyolojik çalışmalar 20. yüzyılın ortalarına kadar dayanmaktadır (Maier ve Dandy, 2000). Yapay sinir ağlarının gelişiminin ana kaynağı, beynimizin düzenli olarak gerçekleştirdiği karmaşık işlemleri yapay, belki zeki davranış gösteren sistemlerin oluşturulabileceği ümididir (Sağiroğlu, 2003).

Yapay sinir ağları ile sayısız uygulamalar yapılmış ve başarılı sonuçlar elde edilmiştir. Geniş bir uygulama alanına sahip yapay sinir ağları ile yapılan işlem alanları; tahmin, sınıflandırma, veri ilişkilendirme, veri filtreleme, tanıma ve eşleştirme, teşhis, yorumlamadır (Duman, 2006). Yapay sinir ağları ayrıca ses tanıma, parmak izi tanıma, el yazısı tanıma, otomatik araç denetimi gibi alanlarda da uygulanmaktadır (Elmas, 2007).

5.2.Yapay Sinir Ağlarının Tarihçesi

Sinir ağları ile alakalı ilk çalışmalar, 19. yüzyılın sonları ile 20. yüzyılın başlarında ortaya çıkmıştır. İlgili ilk çalışma, Helmholtz, Mach ve Pavlov gibi bilim adamları vasıtasıyla geliştirilen disiplinler arası bir çalışmadır. Bu çalışmanın amacı; öğrenme, sezme ve koşullanmanın genel teorisine vurgu yapmaktadır. Yapay sinir hücreleri ile alakalı çalışmaların başlangıç tarihi 1940'lı yıllardır. 1943 senesinde Warren McCulloch ve Water Pitts, yapay sinir hücrelerinin mantıksal yahut aritmetik bir fonksiyon için hesaplama kabiliyeti olduğunu göstermiştir. McCulloch ve Pitts'in geliştirdiği bu ilk model değişime uğrayarak daha sonraki çalışmalarda etraflıca uygulanmıştır (Hamzaçebi, 2011).

5.3. Yapay Sinir Ağlarının Genel Özellikleri

Yapay sinir ağlarının günümüzde kullanımda olan diğer bilgi işlem yöntemlerinden farklılıkları aşağıdaki şekilde sıralanabilmektedir (Seven, 1993; Simpson, 1990; Öztemel, 2003):

Paralellik: Yapay sinir ağlarında işlemler bütün ağa yayılmış vaziyettedir, doğrusal değildir. Bundan dolayı doğrusal olmayan karmaşık problemler için de çözümlenme imkânı vardır.

Bilginin Saklanması: Yapay sinir ağlarında bulunan veriler herhangi bir veritabanında ve programın içinde değil, ağ üzerinde saklıdır.

Öğrenebilirlik: Yapay sinir ağlarının ana fonksiyonu bilgisayarların öğrenmesini gerçekleştirmektir. Tecrübe edindiği olayları benzer olaylar sırasında sunmaya çalışırlar.

Bilginin Saklanması: Yapay Sinir ağlarında veriler ağ üzerinde saklıdır.

Hata Toleransı: Yapay sinir ağlarının paralel yapısı, ağda mevcut tüm bilgilerin tüm bağlantılara ulaşmasını gerçekleştirdiği için bazı bağlantıların yahut hücrelerin etkisiz hale gelmesinin ağın ürettiği bilginin doğruluğunda önemli bir etkisi yoktur.

Genelleme: Yapay sinir ağıları ona sunulan örnekler vasıtası ile daha önce görmediği örnekler hakkında bilgiler sunabilmektedir.

Dereceli Bozulma: Ağların bir eksik ya da problem ile karşılaşmaları durumunda anında bozulmazlar. Hata toleransının mevcudiyeti sebebiyle dereceli bir şekilde bozulma gösterirler.

Uyarlanabilirlik: Yapay sinir ağıları, ağırlıklarının yeniden yapılandırılabilmesine olanak sağladığı için belirli bir problem için eğitilen yapay sinir ağı, problemde meydana gelecek değişimlere göre yeniden eğitilebilir ve farklı durumlara uyum sağlayabilir.

5.4. Yapay Sinir Ağlarının Avantajları ve Dezavantajları

Yapay sinir ağlarının sunduğu en büyük avantaj, öğrenme yeteneğine sahip olması ve çeşitli öğrenme algoritmaları kullanabilmesidir. Yapay sinir ağları esnek ve uyarlanabilir bir yapıya sahiptir. Yapay sinir ağlarının öğretim malzemelerinin değiştirilmesiyle öğrenmesi gerçekleştirilebilir. Yapay sinir ağlarının dezavantajı ise sisteme ait çalışmanın analizinin mümkün olmaması ve öğrenme işlemlerinde başarısızlık riskinin bulunmasıdır (Duman, 2006).

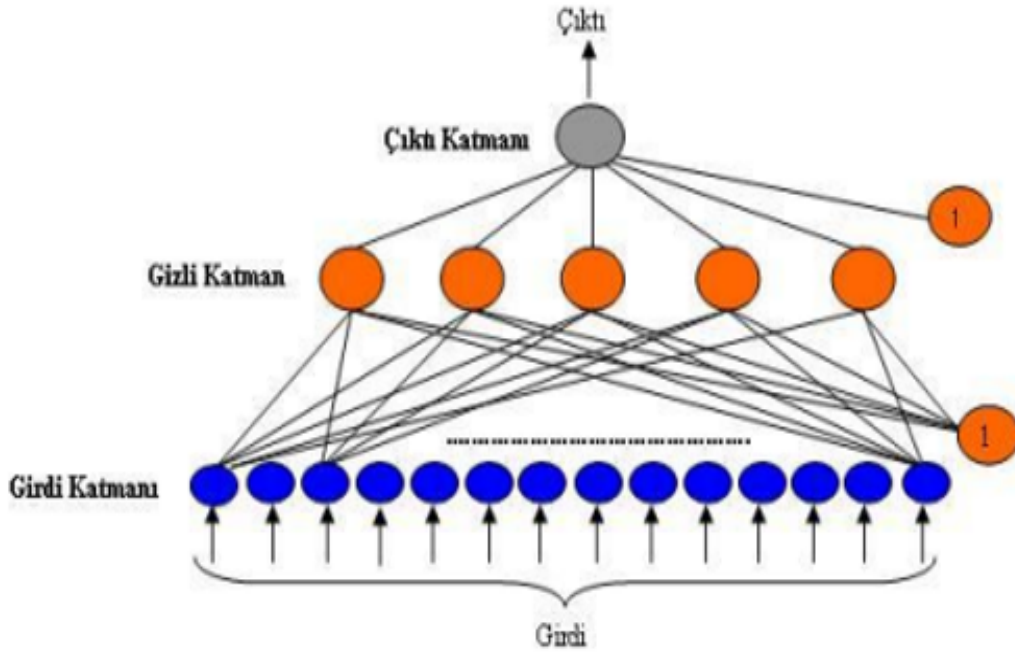
5.5. Yapay Sinir Ağlarının Temel Yapısı ve Temel Bileşenleri

Yapay sinir hücrelerinin bir araya gelmesi ile birlikte yapay sinir ağları oluşur. Bu oluşum rastgele değildir. Yapay sinir ağları 3 farklı katmandan oluşur. Bu katmanlar; girdi katmanı, ara katmanlar ve çıktı katmanlarıdır.

Girdi Katmanı: Girdi katmanında en az bir girdi elemanı mevcuttur. Bu katmanda bulunan veriler herhangi bir işleme maruz kalmadan girdi elemanları ile aynı değerde çıktı elemanı üretirler (Hawley ve Johnson, 1994).

Ara Katmanlar: Bu katmanda girdi elemanları birtakım işlemlere tabi tutulmaktadır. Seçilen ağ yapısı ile işlem katsayısının yapısı ve işlevi de değişim gösterebilir. Tek bir katmandan meydana gelebileceği gibi birden çok katmandan da meydana gelebilmektedir (Chaudhury vd., 1994).

Çıktı Katmanı: Çıktı katmanı en az bir çıktıya sahiptir ve çıktı ağ yapısında bulunan fonksiyona bağlıdır. Bu katmanda işlemler gerçekleştirilmektedir ve elde edilen çıktı dış dünya ile paylaşılmaktadır (Es, 2003).

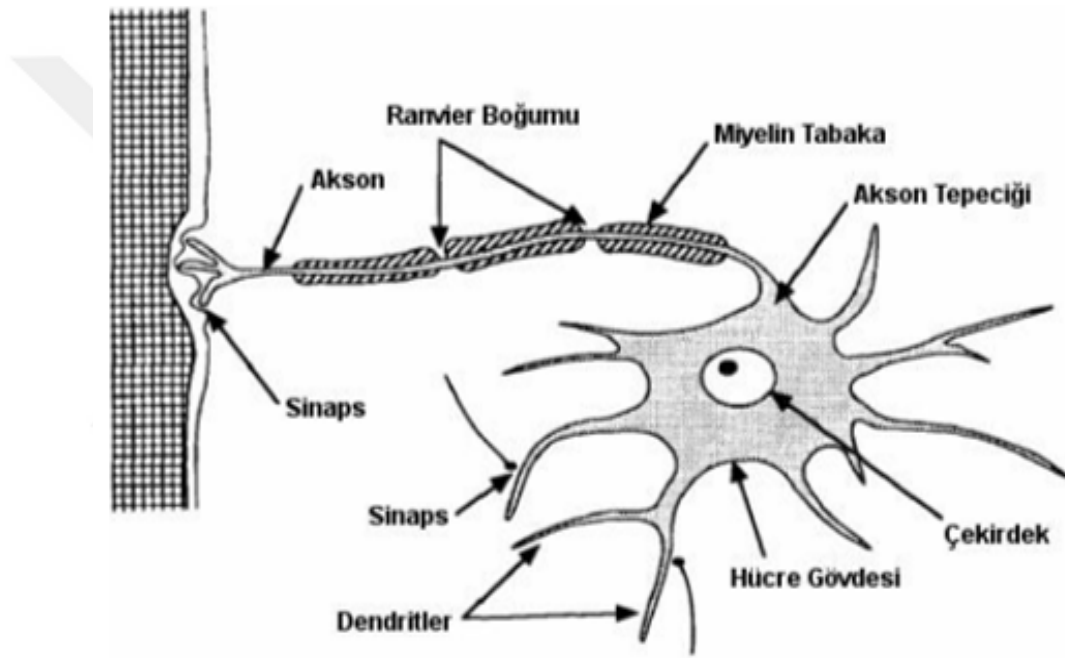


Şekil 5.1. Çok katmanlı bir yapay sinir ağı (Hamzaçebi, 2011)

5.5.1. Biyolojik sinir hücresi

Biyolojik sinir sistemi, merkezinde devamlı olarak bilgiyi alan, yorumlayan ve bunların neticesinde uygun bir karar çıktısı sağlayan beynin bulunduğu üç katmanlı sistem olarak tanımlanmaktadır. Bahsi geçen bu 3 katman; çevreden ulaşan girdileri elektriksel sinyallere çevirerek beyne ileten alıcı sinirler, beyinde üretilen elektriksel sinyalleri çıktı halinde uygun tepkilere çeviren tepki sinirleri, alıcı ve tepki sinirleri arasında ileri ve geri besleme ile uygun tepkiler üreten merkezi ağ olarak tanımlanabilmektedir (Baş, 2006).

Beyin, milyarlarca nörondan meydana gelmektedir. Tüm elemanlar kendi içlerinde oldukça çok sayıda nörona bağlanmıştır. Bir nöronun aksonu (çıkış yolu) ayrıştırılarak, sinaps olarak isimlendirilen bir jonksiyon aracılığıyla diğer nöronların dendritlerine bağlanmıştır. Jonksiyon uçlarında gerçekleşen iletim kimyasaldır ve işaretin miktarı, akson vasıtasıyla serbest kılınan kimyasalların büyüklüğü ile doğru orantılı olarak aktarılır ve dendritler yardımıyla alınır. Bu sinaptik büyüklük, beynin öğrenme aşamasında nelerin değiştirildiğini gösterir. Bu sinaps, beynin ana hafıza işleyişine dayanarak nörondaki bilginin işlenmesi ile birleştirilir (Duman, 2006).



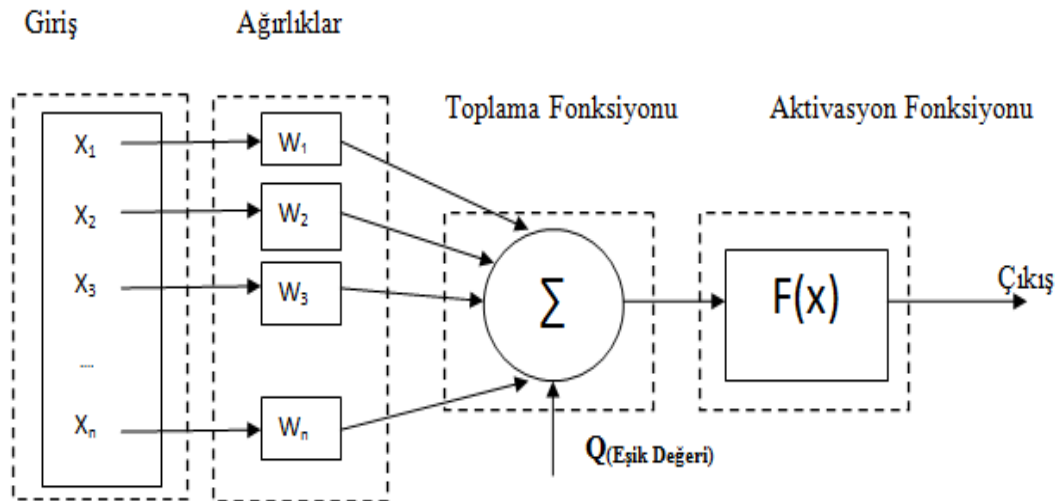
Şekil 5.2. Sinir hücresi (Freeman ve Skapura, 1991)

Tablo 5.1. Sinir sistemi ile YSA'nın benzerlikleri (Sağıroğlu vd., 2003)

Biyolojik Sinir Sistemi	Yapay Sinir Ağları
Sinir Sistemi	Sinirsel Hesap Sistemi
Nöron (Sinir)	İşlem Elemanı
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Aksonlar	Eleman Çıkışı
Sinapslar	Ağırlıklar

5.5.2. Yapay sinir hücresi

Yapay sinir hücresi (YSH), insan sinir hücresini taklit edebilmeyi hedefleyen bir yapıdır. Bir yapay sinir hücresi genelde beş ana birimden meydana gelmektedir. Bunlar; girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktı birimleridir. Girdiler ilk olarak sinir hücresine girerek ilgili bağlantı aralıkları ile çarpım işleme tabi tutulurlar, akabinde bir birleştirme fonksiyonu ile birleştirirler ve böylece nöronun net girdisi ortaya çıkar. Net girdi bir aktivasyon ile işlenir. Aktivasyon fonksiyonuna ait çıktı yardımıyla da nöronun net çıktısı belirlenir (Hamzaçebi, 2011).



Şekil 5.3. Yapay sinir hücresinin matematiksel yapısı (Karahan, 2011; Yüksek, 2007)

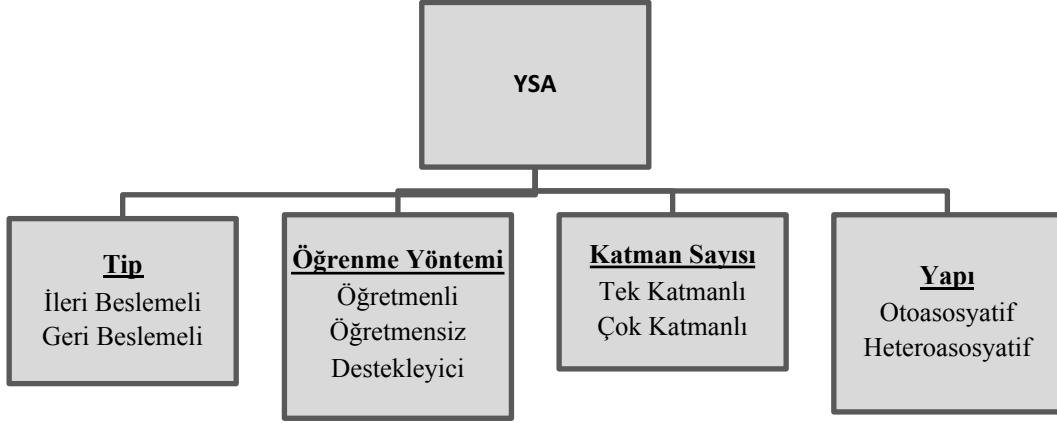
5.6. Yapay Sinir Ağlarının Eğitimi ve Testi

Yapay sinir ağlarında mevcut olan bağlantıların ağırlık değerlerinin değiştirilmesiyle gerçekleşen işleme “ağın eğitilmesi” denir. Yapay sinir ağlarının eğitim süreci, belirli kurallara bağlı olarak gerçekleşmektedir. Bu kurallar ise öğrenme kuralları olarak isimlendirilmektedir. Ağırlıkların değiştirilme işlemi öğrenme kuralları çerçevesinde gerçekleştirilir. Yapay sinir ağlarında, ağırlıkların doğru değerlere ulaşması neticesinde, örneklerin temsilini gerçekleştirdiği problem konusunda ağın “genelleme” yapabilme yeteneğine ulaşması demektir. Bu yeteneğe ulaşma işlemine ise “ağın öğrenmesi” denmektedir (Es, 2013).

Bir yapay sinir ağının eğitimini tamamlamasının ardından, çeşitli denemeler ile ağın öğrenip öğrenmediğinin test edilmesi lazımdır. Bir ağı test edebilmek için ağın eğitimi sürecinde karşılaşmadığı, veri setindeki mevcut test amaçlı ayrılan örneklerden faydalanılır. Ayrılan bu örnekler “test kümesi” olarak isimlendirilmektedir. Test işlemi sırasında ağa ait ağırlık değerlerinde oynama yapılamamaktadır. Örnekler ağa gösterilmekte ve ağ eğitimi sırasında belirlenmiş ağırlık değerleri ile daha önce karşılaşmadığı bu örnekler için çıktılar sunmaktadır. Akabinde elde edilen çıktılar vasıtasıyla ağın öğrenmesi hakkında bilgi sahibi olunur. Elde edilen sonuç neticesinde eğitimin performansı hakkında bilgi sahibi olunur (Öztemel, 2003).

5.7. Yapay Sinir Ağlarının Sınıflandırılması

Literatürde birçok yapay sinir ağı türü vardır. Yapay sinir ağları çeşitli açılardan sınıflandırılabilir.



Şekil 5.4. YSA'ların sınıflandırılması (Hamzaçebi, 2011)

5.7.1. Tipine göre yapay sinir ağları

Yapay Sinir Ağları nöronlar arasında meydana gelen bağlantı durumuna göre ileri beslemeli yahut geri beslemeli olmak üzere iki başlık altında incelenmektedir. İleri beslemeli ağlarda, veriler girdi biriminden başlayarak çıktığı birimine doğru ileri yönlü olarak akış gösterirler. İleri beslemeli ağ yapısında, geri beslemenin aksine, sadece tek yönlü ileriye doğru akış mevcuttur. Geri beslemeli ağlarda ise çift yönlü, ileri ve geri, akış mevcut olup, ağ çıktısının ağ girdisi olarak kullanılma ihtimali mevcuttur (Es, 2013).

5.7.2. Öğrenme yöntemine göre yapay sinir ağları

Yapay sinir ağlarına ait en önemli özelliklerden birisi öğrenme kabiliyetidir. Öğrenme ağın, çevre tarafından uyarılması, eğitilmesi sürecinde ağırlıklarını düzenlemesi işlemine denir. Bu işlemlerin 3 farklı anlam ifade etmektedir (Haykin, 1994).

1. Yapay sinir ağları bulunduğu çevre tarafından uyarılmaktadır.
2. Bu uyarıların neticesinde YSA, önceden belirlenmiş kurallar çerçevesinde, ağırlıklarında bazı değişiklikler uygulamaktadır.
3. YSA, içyapısında meydana gelen değişiklikler neticesinde çevresine çıktı sunmaktadır.

Yapay sinir ağlarının veri yapısında bulunan ilişki öğrenmesini, probleme ait örneklerden faydalanarak ağ ağırlıklarına en uygun değerlerin tayin edilmesi olarak tanımlanabilmektedir. Rastgele bir ağırlık (w için) için;

$$w_{yeni} = w_{eski} + \Delta w \quad (5.1)$$

Denklemini, öğrenme işleminin matematiksel ifadesidir. Eşitlik 5.1' de verilen Δw değeri belirli kurallar çerçevesinde hesaplanarak mevcut ağırlık değerlerine ait değişim miktarını sunar. Δw ' nin belirlenmesi için önceden tanımlı olan kurallar öğrenme algoritmaları olarak isimlendirilmektedir. Bu ağırlık değerinin saptanması için birçok öğrenme algoritması sunulmuştur. Bahsi geçen algoritmalar 3 başlık altında incelenebilmektedir. Bunlar; öğretmenli, öğretmensiz ve destekleyici öğrenme algoritmalarıdır (Haykin, 1994).

5.7.2.1. Öğretmenli öğrenme yöntemi

Öğretmenli öğrenme ya da gözetimli öğrenme, işlevini gerçekleştirebilmesi için bir öğretmene ihtiyaç duymaktadır. Burada bahsi geçen öğretmen, yapay sinir ağlarına öğrenilmesi istenen olay ile alakalı örneklerin hem girdi değerlerini hem girdiler karşılığında olması istenen çıktı değerlerini verendir. Sistemin görevi ise, öğretmen tarafından belirlenen çıktıların haritalanması ve bu vesile ile girdiler ve çıktılar arasındaki ilişkileri öğrenmektir. En çok tercih edilen model olma özelliğine sahip çok katmanlı algılayıcılar modelinde bu yöntemden faydalanılmaktadır (Adıyaman, 2007; Masters, 1993).

5.7.2.2. Öğretmensiz öğrenme yöntemi

Bu yöntemde ise sistemin öğrenme işlevini yerine getirebilmesi için herhangi bir öğretmene ihtiyaç yoktur. Bu yöntemde sisteme sadece girdi değerleri tanıtılır. Örneklerdeki parametreler arasında mevcut olan ilişkileri sistemin kendi kendine

öğrenmesi umulur. Öğrenme işlemi sistem tarafından tamamlandıktan sonra ise çıktıların yorumlanması kullanıcı tarafından gerçekleşmelidir. Öğretmensiz öğrenme yöntemi, genel olarak sınıflandırma için tercih edilen bir yöntemdir (Adıyaman, 2007; Masters,1993).

5.7.2.3. Destekleyici öğrenme

Bu sistemde de öğretmenli öğrenme sistemindeki gibi, ağın işlevini gerçekleştirebilmesi için bir öğretmene ihtiyaç duyulur. Burada bahsi geçen öğretmen, öğretmenli öğrenmenin aksine, olması icap eden çıktıları sistemde tanımlamaz. Bu yöntem sınıflandırma problemlerinde tercih edilen bir öğrenme yöntemidir. Lineer Vektör Parçalama bu öğrenme yöntemi için örnek olarak gösterilebilir (Bayır, 2006).

5.7.3. Yapısına göre yapay sinir ağları

Yapay sinir ağları yapıları bakımından, otoasosyatif ve heteroasosyatif olmak üzere iki başlık altında incelenebilmektedir. Otoasosyatif ağlarda, girdi nöronları aynı zamanda çıktı nöronu olarak görev yapmaktadır. Bu ağlara örnek olarak Hopfield ağları gösterilebilir. Heteroasosyatif ağlar ise, farklı girdi ve çıktı nöronlarına sahip ağ yapılarıdır. Algılayıcı, çok katmanlı algılayıcı, kohonen ağları heteroasosyatif ağları içerisinde yer alır (Mehrotra vd., 1997).

5.7.4. Katman sayılarına göre yapay sinir ağları

Yapay sinir ağları, yapay sinir hücrelerinden meydana gelmektedir. Benzer özelliklere sahip yapay sinir hücrelerinin oluşturduğu kümeye katman denir. Örnek olarak girdi katmanı girdi sinir hücrelerinden, çıktı katmanı ise çıktı sinir hücrelerinden meydana gelmektedir. Bir yapay sinir ağının tek katmandan oluşumuna tek katmanlı YSA, birden fazla katmandan meydana gelmesine ise çok katmanlı YSA denmektedir (Es, 2013).

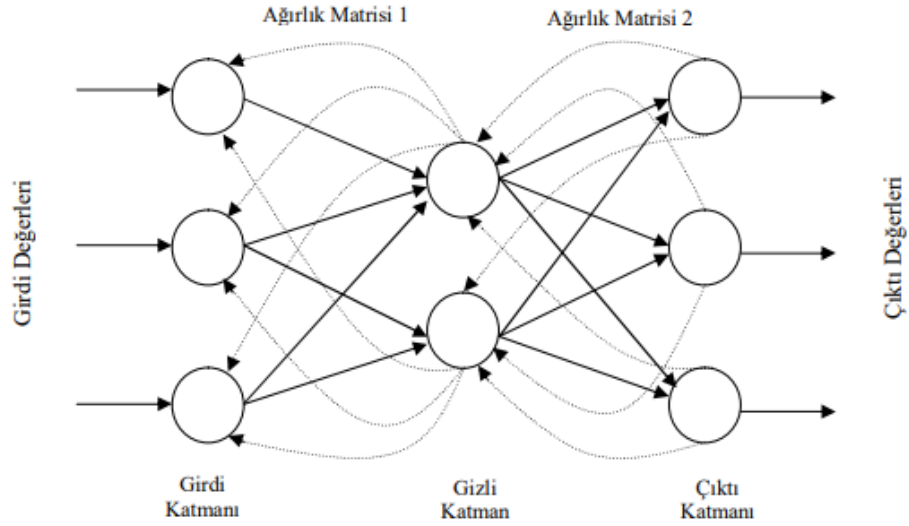
5.7.4.1. Çok katmanlı algılayıcı

Çok katmanlı algılayıcılar (ÇKA); öğrenme metotlarından öğretmenli öğrenmeyi uygulayan bu ağlar, ileri beslemeli yapıya sahiptir. Birden çok katmanı bulunan ÇKA heteroasosyatif YSA yapısına sahiptir. Çok katmanlı algılayıcılar, doğrusal olmayan problemlerde de uygulanabilir olmasından ötürü günümüzde en yaygın kullanılmakta olan yapay sinir ağıdır. Literatürdeki diğer ismi ise, uyguladığı öğrenme algoritması sebebiyle, geri yayılım ağıdır (Es, 2013).

Çok katmanlı algılayıcılar diğer YSA türlerinden 3 noktada ayrılmaktadır (Haykin, 1994). Bunlar;

- Ağdaki her bir nöronun doğrusal olmaması,
- Gizli nöronlardan meydana gelen bir ya da birden çok gizli katmana sahip olması,
- Ağ bağlantılar yardımıyla çok yüksek derecede bilgi işleme becerisidir.

ÇKA, öğretmenli öğrenme yönteminden faydalanmaktadır. Ağ öğrenme işlevini yerine getirebilmek için eğitim kümesi ismi verilen ve örneklerin bir kısmının oluşturduğu sete ihtiyaç duymaktadır. Bu set içerisinde tüm örnekler için hem girdi değerleri hem de o girdi değerleri için ağın üretmesi icap eden çıktılar belirlenir. Öğrenme esnasında tüm örnekler için ağ çıktı değeri ile beklenen çıktı değeri kıyas edilir ve hata değeri ağa tekrar geri besleme olarak verilir. Örnek setinde bulunan hata karelerinin toplamının azaltılması için işlemci arasında mevcut olan bağlantı ağırlıkları değiştirilmelidir. Bir yapay sinir ağı geri yayılım yoluyla eğitilirken; ileri doğru hesaplama ve geriye doğru hesaplama olmak üzere iki aşamadan birisi ile eğitilmektedir (Es, 2013).



Şekil 5.5. İleri beslemeli geri yayılım yapay sinir ağı yapısı (Es, 2013)

İleri doğru hesaplama, yapay sinir ağının çıktısını hesaplama aşamasıdır. Bilgi işleme, girdi setine ait bir örneğin ağıya tanıtılması ile başlamaktadır. Bahsedildiği üzere, girdi katmanında bilgi işleme mevzu bahis değildir. Gelen girdiler hiçbir değişikliğe maruz kalmadan gizli katmana iletilir. Bu durum $y_k^i = x_k$ eşitliği ile ifade edilebilmektedir (Es, 2013).

Gizli katmana ait her işlemci birim, girdi katmanına ait tüm işlemci birimleri tarafından gelen bilgileri bağlantı ağırlıkları ile ağırlandırarak alır. Gizli katmanda bulunan işlemci birimlere gelen net girdi;

$$\delta_j^\alpha = \sum_{k=1}^n w_{jk} y_k^j \quad (5.2)$$

eşitliği ile hesaplanmaktadır. Burada w_{jk} ; k . girdi katma birimini, j . gizli katman birimine bağlayan bağlantıya ait ağırlık değerini; y_k^j ise girdi katmanında bulunan k . işlemci birime ait çıktıyı formüle etmektedir (Es, 2013).

Sigmoid fonksiyonun uygulanması durumunda ise çıktı;

$$y_j^\alpha = \frac{1}{1 + e^{-(s_j^\alpha + \beta_j^\alpha)}} \quad (5.3)$$

yukarıdaki denklem ile hesaplanmaktadır. Formüldeki β_j , gizli katmanda mevcut olan j . elemana bağlı eşik değere ait elemanın ağırlığını ifade etmektedir. Bu ağırlık değeri neticesinde sigmoid fonksiyonun yönü tayin edilir. Eğitim sırasında ağ bu değeri kendisi oluşturur (Öztemel, 2003).

Geriye doğru hesaplama sırasında ise durum; ağa sunulan girdinin ürettiği çıktığı ile ağın beklenen çıktıyı kıyas etmektir. Çıktı katmanında bulunan m . işlemci elemana ait hata;

$$E = d_m - y_m \quad (5.4)$$

denklemleri ile elde edilmektedir. Bu bir tek işlemci elemana ait hatadır. Çıktı katmanı için oluşacak toplam hata ise;

$$E = \frac{1}{2} \sum_m E_m^2 \quad (5.5)$$

denklemleri yardımıyla elde edilir. Toplam hatanın minimize edilebilmesi için işlemci elemanlara ait hatalar önceki katmanlara iletilmektedir. Bu iletim işlemi geri yayılım olarak isimlendirilmektedir. Hatanın önceki katmanlara iletildiği sırada, aktivasyon fonksiyonu türevi yardımı ile aktivasyon işlemi gerçekleştirilmektedir. Hatanın iletimi, katmanlar şeklinde geriye doğru sürmekte ve bu süre zarfında Delta kuralı uygulanarak bağlantı ağırlıkları belirlenmektedir. Süreç girdi katmanına değin devam eder ve o noktada yeni bir döngüye başlanır. Ağın ağırlıklarının değiştirildiği süreçte iki durum gerçekleşmektedir. Bu iki durum; gizli katman ile çıktı katmanı arasında mevcut olan ağırlıkların değiştirilmesi, gizli katmanlar arası veya girdi katmanı ile gizli katman yahut gizli katmanlar arası mevcut ağırlıkların değiştirilmesidir (Es, 2013).

Gizli katman ile çıktı katmanı arasında mevcut olan ağırlığın, j . işlemci biriminin çıktı katmanındaki m . işlemci birime bağlayan bağlantıya ait ağırlık değişim miktarı Δw^α olmak üzere; herhangi bir t zamanında değişim miktarı ise;

$$\Delta w_{jm}^{\alpha}(t) = \lambda \delta_m y_j^{\alpha} + \alpha \Delta w_{jm}^{\alpha}(t-1) \quad (5.6)$$

ile hesaplanmaktadır. Formüldeki bulunan λ öğrenme oranını temsil ederken, α ise momentum katsayısını temsil etmektedir. Öğrenme oranı yardımıyla, bir sonraki seviyede ağırlıkların değişim oranları belirlenmektedir. Öğrenme oranı için küçük değerler seçildiği durumlarda öğrenme süresi uzayabilirken, büyük bir değer seçilmesi durumunda ise ağ yerel çözümlere takılabilmektedir (Es, 2013).

Yerel çözümler ise; ağ eğitimi sırasında en iyi çözümü yakalamaya çalışır, lakin bazı durumlarda ağ farklı bir çözüme takılır ve performans daha fazla iyileştirilemez. Bu çözüm vektörleri yerel çözümler olarak isimlendirilmektedir (Öztemel, 2003).

Momentum katsayısı ise ağ performansı üzerinde etkiye sahip diğer bir etkendir. Yerel çözümlere takınılması durumunda ağların daha iyi sonuçlar üretmesi hedefiyle uygulanır. Momentum katsayısı değerine küçük sayı tayin edilmesi yerel çözümlerden kurtulmayı, büyük sayı tayin edilmesi ise tek bir çözüme ulaşma noktasında işleri zorlaştırmaktadır (Es, 2013).

Eşitlikte mevcut olan δ_m , m . işlemci elemana ait hatayı belirtirken şu formül yardımıyla hesaplanır;

$$\delta_m = f'(s).E_m \quad (5.7)$$

5.7 nolu eşitlikte bulunan $f'(s)$ aktivasyon fonksiyonun türevini ifade etmektedir. Sigmoid fonksiyonun uygulanması durumunda ise;

$$\delta_m = y_m(1-y_m).E_m \quad (5.8)$$

denkleminde faydalanılmaktadır. Değişim miktarının belirlenmesi işlemi sonrası ağırlıkların t . tekrardaki değerleri ise,

$$\Delta w_{jm}^{\alpha}(t) = \Delta w_{jm}^{\alpha}(t-1) + \alpha \Delta w_{jm}^{\alpha}(t) \quad (5.9)$$

formülü uygulanmaktadır. Aynı şekilde eşik değer elemanının da ağırlıklarının değiştirilmesi icap etmektedir. Bu işlem için önce değişim miktarı hesaplanmalıdır. Eğer çıktı katmanında bulunan işlemci elemanların eşik değer ağırlıkları β^o ile gösterilirse, bu elemana ait çıktının sabit ve 1 olmasından ötürü değişim miktarı,

$$\Delta \beta_m^o(t) = \lambda \delta_m + \alpha \Delta \beta_m^o(t-1) \quad (5.10)$$

formülü ile ifade edilecektir. Eşik değer t . tekrardaki ağırlığına ait yeni değer ise,

$$\beta_m^o(t) = \beta_m^o(t-1) + \alpha \Delta \beta_m^o(t) \quad (5.11)$$

denklemleri ile bulunacaktır (Es, 2013).

Geriye doğru hesaplamada, gizli katmanlar arası yahut gizli katman ile girdi katmanı arasında mevcut olan ağırlıkların değiştirilmesi ise diğer aşamadır. Gizli katman ile çıktı katmanı arasında meydana gelen ağırlık değişimlerinde her ağırlık için çıktı katmanından bir işlemci elemanın hatası göz önünde tutulurken, girdi katmanı ile gizli katman veya katmanlar arasındaki ağırlık değişimlerinde çıktı katmanında bulunan tüm işlemci elemanların hatasından payını alması icap etmektedir (Es, 2013). Bu değişim miktarının formüle edilmiş hali ise,

$$\Delta w_{kj}^i(t) = \lambda \delta_j^{\alpha} y_k^i + \alpha \Delta w_{kj}^i(t-1) \quad (5.12)$$

denklemlerde açıklandığı gibidir. Formüldeki hata terimi δ ise,

$$\delta_j^{\alpha} = f'(s) \sum_m \delta_m w_{jm}^{\alpha} \quad (5.13)$$

denklemleri ile elde edilir.

Aktivasyon fonksiyonu olarak sigmoid fonksiyonunun uygulanması halinde ise hata değeri,

$$\delta_j^\alpha = y_j^\alpha (1 - y_j^\alpha) \sum_m \delta_m w_{jm}^\alpha \quad (5.14)$$

eşitliği ile hesaplanır.

Değişim miktarının hesaplanması ardından ağırlıklar için t. tekrarda yeni değerler için,

$$w_{kj}^i(t) = w_{kj}^i(t-1) + \Delta w_{kj}^i(t) \quad (5.15)$$

formülü uygulanmaktadır.

Aynı şekilde gizli katman eşik değeri ağırlıkları için değişim miktarı,

$$\Delta \beta_j^\alpha(t) = \lambda \delta_j^\alpha + \alpha \Delta \beta_j^\alpha(t-1) \quad (5.16)$$

eşitliği ile hesaplanmaktadır. Ağırlıklara ait yeni değerler ise t. tekrarda ise;

$$\beta_j^\alpha(t) = \beta_j^\alpha(t-1) + \Delta \beta_j^\alpha \quad (5.17)$$

denklemleri yardımıyla hesaplanmaktadır. Böylece ağırlıklara ait tüm ağırlıklar değiştirilmiş olur. Bir iterasyon ileriye ve geriye hesaplamalar yapılarak bitirilir. İkinci bir örnek tanımlanarak sonraki iterasyon başlamakta ve aynı işlemler öğrenme işlevini yerine getirilene kadar sürmektedir (Es, 2013).

5.7.4.1.1. Çok katmanlı algılayıcı modellemede önemli noktalar

ÇKA modeli, başarılı tahmin sonuçları elde edebilmede için önemli bir yere sahiptir. Ancak modelleme aşamasından önce problem ile alakalı verilerin toplanma işinden yoğun dikkat gerekmektedir (Es, 2013).

Zaman serisi analizi ile ilgili tahmin problemlerindeki veri ilgili değişkenin serisidir. Kurulacak ÇKA'da girdi ve çıktı nöron değerlerini meydana getirecek olacak veri de bu seride mevcut olan sıralı gözlem değerleridir. Neden-sonuç ilişkisinin var olduğu tahmin modellerinde; bağımlı değişkenin sahip olduğu veriler çıktı nöronunu, bağımsız değişkenin sahip olduğu veriler ise girdi nöronu değerlerini oluşturmaktadır. Tahmin modelleri oluşturulurken değişkenlerin tespitinde dikkatli davranılmalı ve modele faydası olmayan değişkenler tercih edilmemelidir (Hamzaçebi, 2011).

5.7.4.1.2. Ağ yapısı

Çok katmanlı algılayıcının tasarımı oluşturulurken; girdi nöronu sayısı, gizli katman sayısı, gizli nöron sayısı ve çıktı nöronu sayısı belirlenmelidir. Bu değişkenlerin tercihi ilgili problemin yapısına göre değişiklik gösterecektir. En uygun ağ mimarisinin tespitinde, önerilen birtakım tekniklerin varlığına rağmen, bu yöntemlerden hiçbirisi gerçek tahmin problemleri için optimal sonucun garantisini verememektedir. Farklı ifadeyle bu değişkenlerin belirlenmesinde açık-kesin yöntemler mevcut değildir. Bu sebeple, yapay sinir ağlarına ait bir tasarım, bilimsel çalışmadan ziyade sanatsal bir çalışmadır. Ancak modellerin tercihinde işleyişi kolaylaştıracak çeşitli yaklaşımlar mevcuttur. Örnek olarak; model karmaşıklığının engellenmesi amacıyla BIC (Bayesian Information Criterion) istatistiği model belirlemede tercih edilebilir (Hamzaçebi, 2011).

5.7.4.1.3. Girdi nöronu sayısı

Neden-sonuç ilişkisi temelli bir tahmin problemine ilişkin bağımsız değişken sayısı girdi nöronu sayısını sunacaktır. Girdi nöronları veri içerisinde mevcut gizli bilgileri açığa çıkarmada etkin bir role sahiptir. Bundan dolayı en uygun girdi nöronu sayısının doğru tespit edilmesi büyük önem arz etmektedir (Es, 2013).

5.7.4.1.4. Gizli katman sayısı

Tek gizli katmana sahip çok katmanlı algılayıcı problemlerin çözümünde başarılıdır. Lakin bazı durumlarda iki gizli katmana ihtiyaç duyulabilmektedir. Gizli katman sayısında artışa gidiş, hesaplama zamanının artmasına sebep olmakta aynı zamanda ağıın öğrenme yerine ezberlemesine sebebiyet verebilmektedir (Es, 2013).

5.7.4.1.5. Gizli nöron sayısı

Gizli katmanlarda bulunan nöron sayısının tayininde belirli bir kural yoktur. Genel ifadeyle, az sayıdaki gizli nöron veri yapısındaki ilişkiyi çözümlemede, öğrenebilmede başarılı olamayabilir, çok sayıda mevcut gizli nöron ağıın ezberlemesine sebebiyet vermektedir. En uygun gizli nöron sayısının tespitinde, deney tasarımı ya da deneme-yanılma yöntemi uygulanabilmektedir. Tek gizli katmanlı ağlarda gizli nöron sayısının tespiti ile ilgili öneriler, “n” girdi ve “m” çıktı nöronu olmak üzere, şunlardır (Hamzaçebi, 2011):

- a) n
- b) $2n+1$
- c) $2n$
- d) $\sqrt{n.m}$
- e) $0.75n$

5.7.4.1.6. Çıktı nöron sayısı

Çıktı nöronu sayısının hesaplanması diğerlerine nazaran daha kolay ve direk çalışılan problem ile ilgilidir. Neden-sonuç ilişkisine tabanlı tahmin problemlerinde çıktı nöronu sayısı bağımlı değişken sayısı ile eşit alınabilir. Zaman serisi analizi problemlerinde çıktı nöron sayısı, tahmin dönemi ile aynı uzunluğa sahiptir (Es, 2013).

5.7.4.1.7. Aktivasyon fonksiyonu

Aktivasyon fonksiyonu, tahmin problemleri için oluşturulan çok katmanlı algılayıcılarda, ağ üzerinde etkisi olan bir başka önemli etkendir. Hangi

fonksiyonunun uygulanacağına dair net bir kural olmadığı halde aktivasyon fonksiyonunun seçiminin ağ performans üzerinde etkisi vardır (Es, 2013).

Literatürde mevcut çalışmaların birçoğunda gizli katman nöronları için sigmoid (lojistik) yahut hiperbolik tanjant aktivasyon fonksiyonu uygulanırken, çıktı nöronları için uygulanacak fonksiyon hakkında görüş birliği mevcut değildir. Çıktı katman nöronlarında sigmoid, hiperbolik tanjant ya da özdeşlik fonksiyonunun uygulandığı görülmektedir (Hamzaçebi, 2011).

5.7.4.1.8. Veri normalleştirme

Lojistik yahut hiperbolik tanjant gibi doğrusal olmayan aktivasyon fonksiyonları, bir nörona ait çıktıyı (0,1) yahut (-1,1) aralığına sıkıştırmaktadırlar. Bundan dolayı hesaplamada yapılabilecek yanlışlardan korunmak için girdilerin ve çıktıların normalleştirme işlemine tabi tutulması yararlı olacaktır. Veri normalleştirme, eğitime süreci öncesinde gerçekleştirilir. Veriler normalleştirilirken, genel olarak aşağıdaki formüllerden faydalanılmaktadır (Zhang, vd., 1998):

a.) [0,1] aralığı için doğrusal dönüşüm;

$$x_n = \frac{x_0 - x_{min}}{x_{maks} - x_{min}} \quad (5.18)$$

b.) [a,b] aralığı için doğrusal dönüşüm;

$$x_n = (b-a) \frac{x_0 - x_{min}}{x_{maks} - x_{min}} + a \quad (5.19)$$

c.) Basit normalizasyon;

$$x_n = \frac{x_0}{x_{maks}} \quad (5.20)$$

d.) İstatistiksel normalizasyon:

$$x_n = \frac{x_0 - \bar{x}}{s} \quad (5.21)$$

x_n ve x_0 , normalleştirilmiş ve orijinal veriyi temsil ederken, x_{min} , x_{maks} , \bar{x} ve s , sırasıyla minimum, maksimum, ortalama ve standart sapmayı temsil etmektedir.

5.7.4.1.9. Öğrenme algoritması

Ağ eğitiminde çeşitli optimizasyon yöntemleri vardır. En yaygın kullanılan öğrenme algoritması, bir gradyan dik iniş algoritmasıdır. Öğrenme oranı ve momentum katsayılarının tespitinde gradyan dik iniş algoritması önemli bir role sahiptir. Öğrenme parametrelerine ait değerler genellikle deneme-yanılma yöntemiyle belirlenir. Öğrenme oranı ve momentum katsayısı, ekseriyetle 0 ile 1 arasında değerler alabilirler (Es, 2013).

5.7.4.1.10. Veri kümesinin düzenlenmesi

Çok katmanlı algılayıcının performansında etkisi olan bir diğer etmen ise veri kümesinin büyüklüğüdür. Veri kümesine ait büyüklük, diğer istatistiksel yaklaşımlardaki gibi, çözümün doğruluğuna direkt etkisi vardır. Verilen bir problemi ÇKA vasıtasıyla çözebilmek için ne kadar büyüklükte bir örneğe ihtiyaç duyulduğu; ağın yapısı ve veri içerisindeki karmaşıklıkla ilgilidir. Yeterli sayıda veri ile birlikte ÇKA, veride mevcut olan herhangi karmaşık bir yapıyı modelleyebilmektedir. (Zhang, vd., 1998).

Birçok katmanlı algılayıcı ile tahmin çalışmasında eldeki mevcut veri kümesi eğitim-test yahut eğitim-doğrulama-test gibi kısımlara ayrılır (Es, 2013). Bu kümelerin belirlenmesi için literatürde bazı öneriler mevcuttur. Araştırmacılar %80, %10, %10 yahut %60, %20, %20 gibi kurallar etrafında veri kümeleri oluşturmuşlardır. Bu oranlar ile veri sayısı arasında doğrusal bir ilişkiye sahiptir (Zhang, vd., 1998).

5.7.4.1.11. ÇKA'nın performansının belirlenmesi

Tahmin amacıyla kurulan çok katmanlı algılayıcı modellerinin performansının belirlenirken tahminin doğruluğu baz alınmaktadır. Tahminin doğruluğu ise tahmin modelinin hatalarının analizi ile belirlenmektedir. Tahmin hatası, gerçek gözlem değeri ile tahmin edilen değer arasında gerçekleşen farktır. Tahmin hatası,

$$e = Y - F \quad (5.22)$$

5.22 nolu denklem yardımıyla hesaplanır. Y , gerçek gözlem değerini F ise model tarafından üretilen değeri ifade etmektedir. Tarafsız bir tahmin sonucu elde etmek için, gözlem değerlerinin fazlaca olması önem arz etmektedir. Tahmin doğruluğunun tespitinde çeşitli doğruluk ölçütleri tanımlanmıştır. Sıklıkla kullanılan performans ölçütleri aşağıdaki denklemlerde gösterilmiştir (Hamzaçebi, 2011). Herhangi bir problem için birden fazla performans ölçütü kullanılabilir (Es, 2013).

$$\text{Ortalama Hata (OH)} = \frac{1}{n} \sum_{i=1}^n e_i \quad (5.23)$$

$$\text{Ortalama Mutlak Hata (OMH)} = \frac{1}{n} \sum_{i=1}^n |e_i| \quad (5.24)$$

$$\text{Hata Kareleri Toplamı (HKT)} = \sum_{i=1}^n e_i^2 \quad (5.25)$$

$$\text{Hata Kareleri Ortalaması (HKO)} = \frac{1}{n} \sum_{i=1}^n e_i^2 \quad (5.26)$$

$$\text{Ortalama Mutlak Yüzde Hata (OMYH)} = \frac{1}{n} \sum_{i=1}^n \left| \frac{e_i}{Y_1} \right| * 100 \quad (5.27)$$

5.8. Yapay Sinir Ağlarında Öğrenme

Bu başlık altında yapay sinir ağlarının öğrenme yöntemlerinden bahsedilecektir

5.8.1. Hata-düzeltilme öğrenimi

Öğretmenli öğrenme yöntemi olarak uygulanan hata düzeltme öğrenimi, sistem tarafından sunulan çıktıyı gerçek çıktı ile kıyaslayan ve hatayı eğitime yönlendirmek için uygulanan bir tekniktir (Belciug ve Gorunescu, 2014).

5.8.2. Bellek tabanlı öğrenme

Bellek tabanlı öğrenme; doğal dil işleme sınıflandırma problemlerinde öğrenme sağlanması hedefiyle uygulanan bir yöntemdir (Daelemans vd., 2003). Bu öğrenme sisteminde geçmişte kazanılan tecrübelerin tümü veya çoğu doğru şekilde tasnif edilmiş olarak giriş çıkış örneklerine ait belleklerde saklanmaktadır (Ahamed ve Akthar, 2016).

5.8.3. Hebbian öğrenme

Hebbian öğrenme yöntemi Danimarkalı nöropsikolog Donald Holding Hebb tarafından geliştirilmiştir. Bu kurala göre; sinyal alan ve sinyal gönderen nöronlar aynı işarete sahip ise yahut başka deyişle beraber ateşleniyorlarsa bu iki nöronun sahip olduğu bağ güçlendirilmelidir. Aksi durumda ise bağın gücü azaltılmalıdır. Beraber ateşlendikleri ya da kuvvetlendirildiklerinde daha güçlü etkiye sahip bu nöronlar ayrı olarak kuvvetlendirildikleri zaman aynı etkiye sahip olamayabilirler. Başka bir tanım ile bu yöntem, daha önceden belli olan sabit bir değer ile bağlantı ağırlıklarının işaret değiştirmesine bağlı olarak çalışmaktadır (Şen, 2004).

5.8.4. Rekabetçi öğrenme

Hebbian öğrenme yönteminin çeşitlerinden biri olan rekabetçi öğrenme, ağdaki her bir düğümün, girdi değerlerini en iyi şekilde temsil edebilmek için, uzmanlaşmasını arttırmasıyla çalışır (Hinton vd., 2006). Bu yöntemde girdi verileri cevap verebilmek için birbirleriyle rekabet halindedir (Rumelhart ve Zipser, 2005).

5.8.5. Boltzman öğrenmesi

Bir stokastik öğrenme kuralı olan bu yöntem, ikili birimlerden meydana gelen simetrik ağlardır. Hata düzeltme öğrenmesine benzeyen bu yöntem aynı zamanda öğretmenli öğrenme sisteminde de kullanılabilir (Jain vd., 1996).

5.8.6. Hopfield öğrenme kuralı

Hebb kuralı ile benzer özelliklere sahip bu öğrenme kuralının Hebb yönteminden farkı bağlantıya ait ağırlıkların sadece işaretlerinin değil büyüklüklerinin de değiştirilmesinin uygulanmasıdır. Öğrenme oranı sabit bir değer olmak üzere genel olarak 0 ile 1 arasında değer almaktadır (Efendigil, 2008; Kohonen ve Barna, 1987).

5.8.7. Delta kuralı

Bu kuralın çalışma prensibi ise, ağırlık çalıştırılması akabinde beklenen değerler ile ağırlık çalıştırdıktan sonra elde edilen değerler arasındaki farkın azaltılması amacıyla ağırlık bağlantı ağırlıklarının devamlı olarak değiştirilmesi prensibine dayanmaktadır (Yetkin, 2005).

5.8.8. Kohonen kuralı

Bu kuralda ise, sinir hücreleri en büyük çıktıyı vermeyi hedefleyerek birbiriyle rekabet etmektedir. Rekabette amaç ise bir hücre için en büyük çıktıyı sunmak ve ağırlık kendisine ait ağırlığın değiştirilmesidir (Taşova, 2011).

6. TALEP TAHMİN UYGULAMASI

Perakende sektöründe firmalar, gittikçe kızışan rekabet ortamına uyum sağlayabilmek için stoksuz kalma ve aşırı stok gibi durumlara çözümler bulmak zorundadırlar. Müşteri memnuniyetsizliğine sebep olan, stoksuz kalma durumu ile firmalara ağır maliyetleri olan aşırı stoklar, talep tahmin modellerinden faydalanılarak ortadan kaldırılmak istenmektedir.

Perakende sektöründe talep tahmininin YSA ile tahmin edildiği bu tez çalışmasına ait uygulama bölümü; veri, YSA uygulaması, bulgular, ARIMA modelleri ile karşılaştırma ve tahmin kısımlarından oluşmaktadır.

Yapay Sinir Ağları ile talep tahmini uygulanırken, İstanbul Ümraniye’de bulunan bir süpermarketin kasap reyonuna ait verilerden faydalanılmıştır. Uzman görüşleri ile satış verilerinin incelenmesi neticesinde, kasap reyonuna ait et verilerinin sırasıyla; dana eti, kuzu eti ve tavuk eti olarak incelenmesinde karar kılınmış ve çalışma bu şekilde gerçekleştirilmiştir. Çalışmada üç farklı et türüne ait geçmiş bilgiler ile ileriye dönük tahminler yapmak hedeflenmiştir. Nihai talep tahmin modelleri, son dönemlerde talep tahmin modellerinde sıklıkla kullanılan Yapay Sinir Ağları ile ARIMA modellerinin kıyası ardından, en iyi performansı sunan Yapay Sinir Ağları modelleri ile oluşturulmuştur. Yapay Sinir Ağları modelleri Weka adlı paket program vasıtasıyla çözümlenirken, ARIMA modelleri ise EViews adlı paket program vasıtasıyla çözümlenmiştir. Talep tahmin aşamaları aşağıdaki gibi uygulanmıştır.

6.1. Veri


Çalışmanın örneklemini, üç farklı et türü için de 1 Ocak 2017 tarihi ile 31 Aralık 2018 tarihleri arasında gerçekleşen, 104 haftalık dana ve tavuk eti talebi miktarları ile 97 haftalık kuzu eti talep miktarı oluşturmaktadır. Bu tarihler arasında 3 farklı et ürünü için gerçekleşen talep miktarları aşağıdaki tabloda belirtilmiştir.

Tablo 6.1. 2017 – 2018 yılları arasında gerçekleşen 3 farklı et türü talep miktarları

Dönem	Tavuk Eti/ Miktar (kg)	Kuzu Eti/ Miktar (kg)	Dana Eti/ Miktar (kg)
2017.01	748,90	39,76	259,43
2017.02	787,98	33,86	260,43
2017.03	684,28	27,63	261,43
2017.04	669,23	33,41	263,25
2017.05	648,96	28,92	274,86
2017.06	679,71	47,91	289,29
2017.07	685,92	38,8	250,35
2017.08	697,90	42,86	299,20
2017.09	751,23	41,53	293,80
2017.10	709,54	24,03	315,26
2017.11	681,83	32,10	311,96
2017.12	634,37	33,90	330,55
2017.13	638,75	34,76	297,30
2017.14	607,02	35,39	339,03
2017.15	737,60	37,17	368,30
2017.16	598,91	23,89	308,39
2017.17	761,16	43,14	358,29
2017.18	682,56	29,00	295,14
2017.19	790,33	31,47	346,75
2017.20	674,67	37,62	379,42
2017.21	904,36	40,02	603,66
2017.22	793,64	41,99	610,20
2017.23	775,57	31,35	600,78
2017.24	748,99	33,87	593,93
2017.25	813,23	33,45	558,37
2017.26	769,99	12,04	285,77
2017.27	598,19	21,25	305,97
2017.28	592,32	22,03	319,03
2017.29	654,87	32,68	297,60
2017.30	683,22	18,26	277,64
2017.31	525,42	23,22	308,98
2017.32	559,21	5,84	320,27
2017.33	556,17	11,71	289,12

2017.34	572,84	18,49	262,92
2017.35	393,08	3,69	351,58
2017.36	345,53	9,41	657,06
2017.37	389,84	14,88	145,68
2017.38	434,14	13,96	122,23
2017.39	409,95	12,34	105,32
2017.40	508,36	16,84	147,29
2017.41	472,00	15,68	140,64
2017.42	486,28	7,84	152,43
2017.43	538,17	12,34	177,70
2017.44	530,53	14,07	183,47
2017.45	521,08	21,96	205,57
2017.46	544,44	19,19	155,48
2017.47	548,14	17,94	195,50
2017.48	629,65	14,95	160,27
2017.49	550,81	28,83	205,60
2017.50	518,25	22,11	230,99
2017.51	575,47	18,40	245,51
2017.52	678,91	21,30	248,99
2018.01	679,37	14,81	256,31
2018.02	585,08	15,60	262,51
2018.03	541,52	21,61	264,50
2018.04	614,18	12,70	233,64
2018.05	595,88	13,07	283,96
2018.06	609,74	20,95	264,29
2018.07	552,74	16,63	261,21
2018.08	564,79	11,91	319,30
2018.09	604,11	17,56	275,11
2018.10	633,07	22,20	287,07
2018.11	553,34	13,85	282,62
2018.12	584,37	22,50	285,10
2018.13	569,52	26,90	305,39
2018.14	559,70	29,19	344,33
2018.15	583,63	42,34	314,85
2018.16	654,04	36,36	304,68
2018.17	760,46	27,64	346,99
2018.18	673,32	28,03	377,02
2018.19	610,35	28,23	357,09
2018.20	830,76	8,68	649,00
2018.21	774,32	14,92	554,07
2018.22	791,43	9,59	605,51

2018.23	714,21	8,85	530,11
2018.24	697,91	10,53	429,62
2018.25	519,49	16,81	331,27
2018.26	561,46	13,48	266,55
2018.27	687,56	14,43	297,29
2018.28	807,90	10,44	266,93
2018.29	460,27	8,66	247,47
2018.30	508,86	8,05	292,81
2018.31	523,82	9,70	256,08
2018.32	483,99	8,11	250,91
2018.33	465,66	26,85	213,30
2018.34	336,31	13,88	235,80
2018.35	303,70	7,41	275,63
2018.36	359,36	11,78	155,74
2018.37	386,07	10,54	146,76
2018.38	408,34	22,63	184,30
2018.39	371,67	18,46	135,07
2018.40	358,78	12,04	125,28
2018.41	423,44	16,26	133,90
2018.42	404,00	11,08	136,75
2018.43	434,87	15,05	149,91
2018.44	419,66	30,73	179,11
2018.45	460,03	21,67	182,36
2018.46	491,29	21,43	179,52
2018.47	504,70		186,27
2018.48	638,82		202,07
2018.49	476,23		213,09
2018.50	487,82		246,38
2018.51	632,19		227,07
2018.52	564,66		231,26




Şekil 6.1. 2017 – 2018 yılları arasında gerçekleşen 3 farklı et türü talep miktarları grafiği

6.2. Yapay Sinir Ağları Uygulaması

Yapay sinir ağları uygulamasında kullanılacak olan WEKA paket programı, çok katmanlı algılayıcı modelini geri besleme algoritması ile ve delta öğrenme kuralıyla çözümlenmektedir. Bu sebeple 3 farklı et türü için de katman sayısı, öğrenme algoritması ve kuralı eşit olacaktır.

6.2.1. YSA ile dana eti talep tahmini

Talep tahmin çalışmamızda ilk aşama dana eti talep tahmini olacaktır. Tahmin modeli oluşturulurken çok katmanlı algılayıcı modeller kullanılmıştır. Deneme-yanılma yöntemleri neticesinde, bu modelde; gizli katman sayısı 2, öğrenme katsayısı 0.1, momentum katsayısı 0.3 olarak belirlenmiştir. Aşağıdaki grafikte, bu değerler neticesinde gerçekleşen tahmin değerleri gösterilmiştir.



Şekil 6.2. WEKA paket programında dana eti talep tahmini grafiği

Şekil 6.2’de Yapay Sinir Ağları ile %99 güven aralığında, dana eti talep tahmini için WEKA yazılımının çalışma prensibi gereği, çok katmanlı algılayıcı modelini geri besleme algoritması ve delta öğrenme algoritması ile birlikte geçmişteki satış verilerinden faydalanarak ileriye dönük talep tahmininin grafiği verilmiştir.


7 haftalık dana eti talep tahminin gerçekleştiği modelde tahmin hatası performans ölçütleri aşağıda tablo 6.2’de verilmiştir.

Tablo 6.2. Dana eti talep tahmin hatasının doğruluk ölçütleri

MAE	MAPE	RMSE	MSE
5.9111	2.4279	8.3971	70.5108

6.2.2. YSA ile kuzu eti talep tahmini

Talep tahmin çalışmamızda ikinci aşama kuzu eti talep tahmini olacaktır. Tahmin modeli oluşturulurken çok katmanlı algılayıcı modeller kullanılmıştır. Deneyimlenilen yöntemleri neticesinde, bu modelde; gizli katman sayısı 2, öğrenme katsayısı 0.2, momentum katsayısı 0.3 olarak belirlenmiştir. Aşağıdaki grafikte, bu değerler neticesinde gerçekleşen tahmin değerlerinin grafiği sunulmuştur.



Şekil 6.3. WEKA paket programında kuzu eti talep tahmini grafiği

Şekil 6.3’de Yapay Sinir Ağları ile %99 güven aralığında, kuzu eti talep tahmini için WEKA yazılımının çalışma prensibi gereği, çok katmanlı algılayıcı modelini geri besleme algoritması ve delta öğrenme algoritması ile birlikte geçmişteki satış verilerinden faydalanarak ileriye dönük talep tahmininin grafiği verilmiştir.

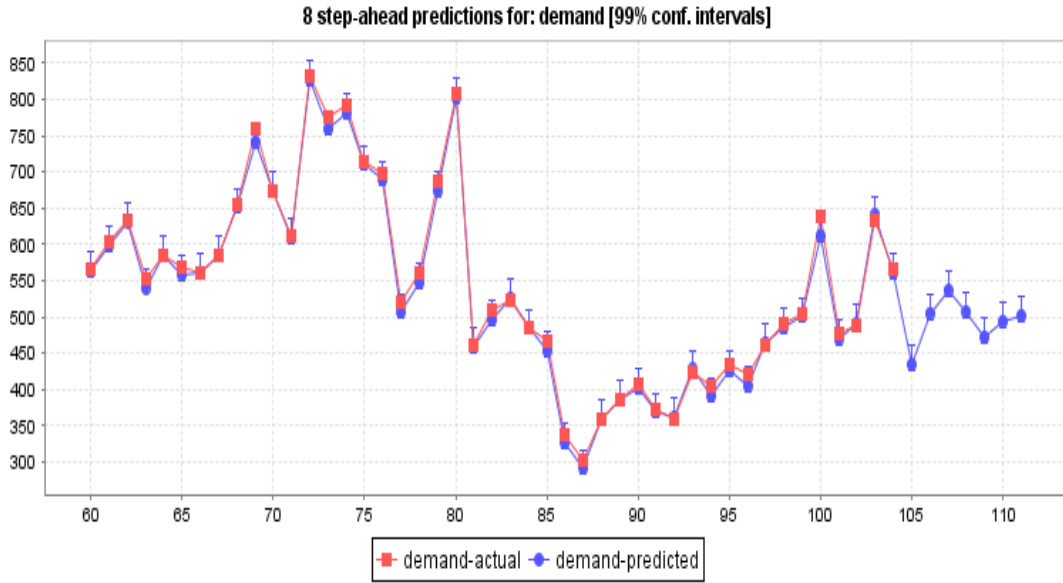
7 haftalık kuzu eti talep tahminin gerçekleştiği modelde tahmin hatası performans ölçütleri aşağıda tablo 6.3’de verilmiştir.

Tablo 6.3. Kuzu eti talep tahmin hatasının doğruluk ölçütleri

MAE	MAPE	RMSE	MSE
0.1991	1.2077	0.3846	0.1215

6.2.3. YSA ile tavuk eti talep tahmini

Talep tahmin çalışmamızda üçüncü aşama tavuk eti talep tahmini olacaktır. Tahmin modeli oluşturulurken çok katmanlı algılayıcı modeller kullanılmıştır. Deneme-yanılma yöntemleri neticesinde, bu modelde; gizli katman sayısı 4, öğrenme katsayısı 0.5, momentum katsayısı 0.2 olarak belirlenmiştir. Aşağıdaki grafikte, bu değerler neticesinde gerçekleşen tahmin değerlerinin grafiği sunulmuştur.



Şekil 6.4. WEKA paket programında tavuk eti talep tahmini grafiği

Şekil 6.4’de Yapay Sinir Ağları ile %99 güven aralığında, tavuk eti talep tahmini için WEKA yazılımının çalışma prensibi gereği, çok katmanlı algılayıcı modelini geri besleme algoritması ve delta öğrenme algoritması ile birlikte geçmişteki satış verilerinden faydalanarak ileriye dönük talep tahmininin grafiği verilmiştir.

7 haftalık tavuk eti talep tahminin gerçekleştiği modelde tahmin hatası performans ölçütleri aşağıda tablo 6.4’de verilmiştir.

Tablo 6.4. Tavuk eti talep tahmin hatasının doğruluk ölçütleri

MAE	MAPE	RMSE	MSE
7.352	1.424	9.228	85.171

Tablo 6.5. Dana, kuzu ve tavuk eti için ileriye dönük 7 haftalık talep tahmin değerleri

DÖNEMLER (HAFTA)	DANA ETİ	KUZU ETİ	TAVUK ETİ
1	257.063	12.270	434.125
2	231.113	30.703	504.867
3	200.956	11.285	534.626
4	386.216	33.153	505.262
5	324.981	16.795	471.403
6	378.0986	40.201	494.659
7	572.189	45.013	502.001


Tablo 6.5.'de daha önce aşamaları ve grafikleri verilmiş üç farklı et türü için ileriye dönük talep tahmin değerleri verilmiştir.

6.3. ARIMA Modellerinin Uygulanması

Bu kısımda, yapay sinir ağları ile kıyaslama yapabilmek için, zaman serisi analizleri modellerinden olan ARIMA modelleri ile talep tahmini gerçekleştirilecektir.

6.3.1. Kuzu eti talebi

Zaman serisi analizlerinde ilk olarak serinin durağanlığı tespit edilir. Serinin durağanlığına ilişkin kesin karar birim kök testleri ile verilse de seri grafiği vasıtasıyla durağanlık hakkında yorum yapabilmek mümkündür.



Şekil 6.5. 2017-2018 yılları arasında gerçekleşen kuzu eti talep miktarları grafiği

Şekil 6.5'de kuzu etine olan talep miktarı verilmektedir. Grafikten kuzu eti talebi serisinin durağan bir seri olduğu anlaşılmaktadır. Yine de birim kök testleri vasıtasıyla emin olmak adına aşağıdaki tabloda birim kök test sonuçları paylaşılmıştır.

Null Hypothesis: KUZU has a unit root
 Exogenous: Constant
 Lag Length: 1 (Automatic - based on SIC, maxlag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-3.774111	0.0043
Test critical values:		
1% level	-3.495677	
5% level	-2.890037	
10% level	-2.582041	

*MacKinnon (1996) one-sided p-values.


Augmented Dickey-Fuller Test Equation
 Dependent Variable: D(KUZU)
 Method: Least Squares
 Date: 05/02/19 Time: 22:40
 Sample (adjusted): 3 104
 Included observations: 102 after adjustments

Variable	Coefficient	Std. Error	t-Statistic	Prob.
KUZU(-1)	-0.340237	0.090150	-3.774111	0.0003
D(KUZU(-1))	-0.262369	0.095199	-2.756013	0.0070
C	7.062199	2.033203	3.473435	0.0008
R-squared	0.284482	Mean dependent var	-0.048922	
Adjusted R-squared	0.270027	S.D. dependent var	8.596405	
S.E. of regression	7.344638	Akaike info criterion	6.854789	
Sum squared resid	5340.426	Schwarz criterion	6.931994	
Log likelihood	-346.5942	Hannan-Quinn criter.	6.886052	
F-statistic	19.68061	Durbin-Watson stat	1.985473	
Prob(F-statistic)	0.000000			

Şekil 6.6. EViews paket programı ile birim kök testi

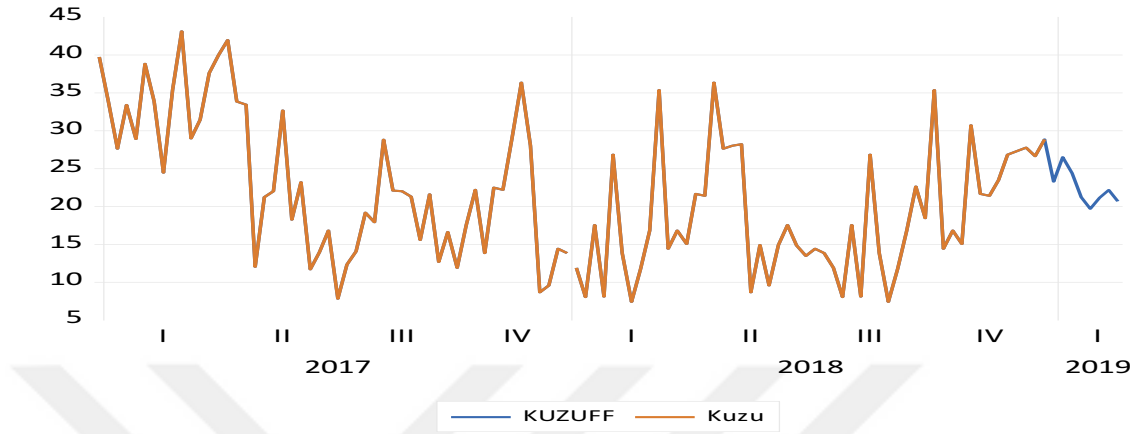
Birim kök testleri ile de kuzu eti talebi serisinin durağan olduğu anlaşılmıştır. Bu sebeple ARIMA modelleri yerine ARMA modelleri arasından talep tahmin modeli oluşturulacaktır. Sonraki aşama bilgi kriterleri yardımıyla en uygun ARMA modelini tespit etmektir.

Akaike Information Criteria (top 20 models)



Şekil 6.7. Bilgi Kriterleri Yöntemi ile en uygun modelin tespit aşaması

Şekil 6.7'den anlaşılacağı üzere bilgi kriterleri yöntemine göre en uygun model ARMA(4,2) olarak tespit edilmiştir. Kuzu eti talep tahmini için ARMA(4,2) modelinden faydalanılmıştır. 2019 yılı ilk 8 haftası için gerçekleşen talep tahmin değerleri, grafiği ve hata performans ölçütleri aşağıda şekil 6.8'de verilmiştir.



Şekil 6.8. EViews paket programında kuzu eti talep tahmini grafiği

6.3.2. Dana eti talebi

İlk aşama serinin durağan olup olmadığının birim kök testleri ile test edilmesidir. Gerek PhillipsPerron gerekse ADF birim kök testleri ile serinin durağanlığı test edilmiştir. Sabit, trendli ve hem sabit hem de trendli yapılan birim kök testlerinin tümünde %5 anlamlılık düzeyinde dana eti talebi durağan çıkmamıştır. ADF birim kök testlerine ilişkin sonuçlara aşağıda yer verilmiştir.

ADF Testi Sabit Terim ile

Null Hypothesis: DANA has a unit root
Exogenous: Constant
Lag Length: 0 (Automatic - based on SIC, mailbag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.724136	0.0734
Test critical values:		
1% level	-3.495021	
5% level	-2.889753	
10% level	-2.581890	

Şekil 6.9.EViews paket programı ile birim kök testi

ADF Testi Sabit Terimsiz

Null Hypothesis: DANA has a unit root
Exogenous: None
Lag Length: 0 (Automatic - based on SIC, mailbag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-1.078503	0.2526
Test critical values: 1% level	-2.587607	
5% level	-1.943974	
10% level	-1.614676	

Şekil 6.10.EViews paket programı ile birim kök testi

ADF Testi Trendli

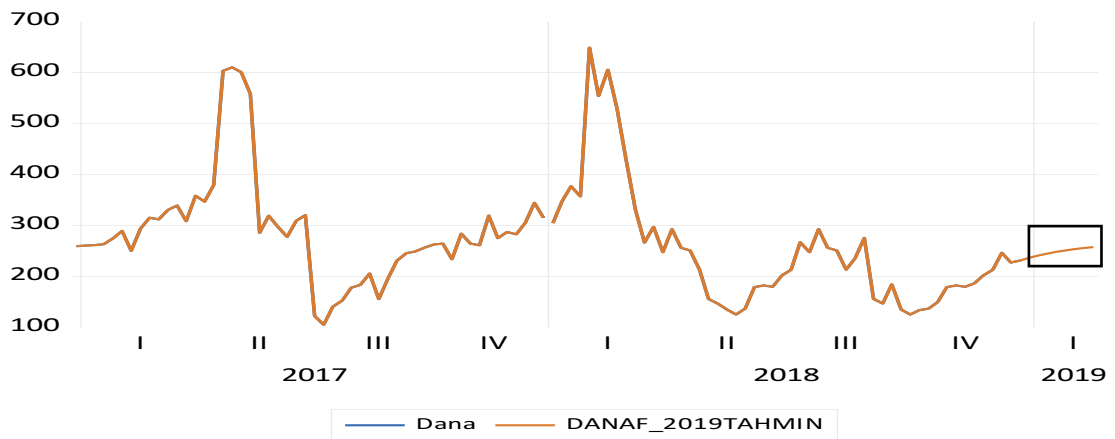
Null Hypothesis: DANA has a unit root
Exogenous: Constant, Linear Trend
Lag Length: 0 (Automatic - based on SIC, mailbag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-2.989593	0.1402
Test critical values: 1% level	-4.049586	
5% level	-3.454032	
10% level	-3.152652	

Şekil 6.11. EViews paket programı ile birim kök testi

Görüleceği üzere her üç testte de ADF istatistiğine ilişkin p-değeri %5'in üzerinde çıkmış bu da dana eti talebinin durağan olmadığını göstermektedir.

Uygun ARIMA modelinin tespiti için korelegram testi, bilgi kriterleri yöntemi ve deneme-yanılma gibi yöntemler mevcuttur. Çalışmamızda, çeşitli denemeler neticesinde, dana eti talebi serisi için uygun modelin AR(2) modeli olduğu tespit edilmiştir. AR (2) modeli ile ileriye dönük haftalık tahmin değerleri, grafiği ve tahmin hata-performans ölçütleri aşağıda şekil 6.12'de verilmiştir.



Şekil 6.12.EViews paket programında dana eti talep tahmini grafiği

6.3.4. Tavuk eti talebi


Diğer et türlerinde olduğu gibi tavuk etinde de ilk aşama durağan olup olmadığının tespit edilmesidir.

Null Hypothesis: TAVUK has a unit root
Exogenous: None
Lag Length: 3 (Automatic - based on SIC, mailbag=12)

	t-Statistic	Prob.*
Augmented Dickey-Fuller test statistic	-0.713289	0.4054
Test critical values: 1% level	-2.588292	
5% level	-1.944072	
10% level	-1.614616	


Şekil 6.13.EViews paket programı ile birim kök testi

Tavuk eti talebi serisi de birim kök testleri sonuçları neticesinde durağan değildir.



Şekil 6.14.Uygun modelin tespiti için modellerin kıyaslanması

Şekil 6.14’de uygun modelin tespiti için modeller kıyaslanmıştır. Bu kıyaslama neticesinde ARMA(2,4) modelinin en uygun model olduğu tespit edilmiştir.



Şekil 6.15. EViews paket programında tavuk eti talep tahmini grafiği

Şekil 6.15’de uygun modelin tespit ardından gerçekleştirilen talep tahmin çalışmasının grafiği verilmiştir. Talep tahmin modeli ARMA(2,4) modeli ile ileriye dönük 7 haftalık tavuk eti talep tahmini gerçekleştirilmiştir. Elde edilen değerler tablo 6.6’ da verilmiştir.

Tablo 6.6. ARIMA modelleri ile elde edilen tahmin değerleri

DÖNEMLER	DANA ETİ	KUZU ETİ	TAVUK ETİ
1	241.119	26.509	592.989
2	245.008	24.408	554.594
3	248.337	21.235	558.756
4	251.189	19.699	565.596
5	253.630	21.157	569.110
6	255.721	22.174	574.217
7	257.511	20.679	577.127

6.4. Yapay Sinir Ağları ve ARIMA Modellerinin Karşılaştırılması

Aşağıdaki tablolarda yapay sinir ağları ve ARIMA modelleri ile üç farklı et türü için yapılan tahminlerin, tahmin hataları doğruluk ölçütleri karşılaştırılmaları verilmiştir.

Tablo 6.7. YSA ve ARIMA modellerinin dana eti tahmin hatasının doğruluk ölçütleri karşılaştırması

TAHMİN ÇEŞİDİ	MAE	MAPE
YSA	5.9111	2.4279
ARIMA	25.391	15.7521

Tablo 6.8. YSA ve ARIMA modellerinin kuzu eti tahmin hatasının doğruluk ölçütleri karşılaştırması

TAHMİN ÇEŞİDİ	MAE	MAPE
YSA	0.1991	1.2077
ARIMA	5.8383	29.280

Tablo 6.9. YSA ve ARIMA modellerinin tavuk eti tahmin hatasının doğruluk ölçütleri karşılaştırması

TAHMİN ÇEŞİDİ	MAE	MAPE
YSA	7.352	1.424
ARIMA	48.26224	10.3951

Yapay sinir ağı modelleri neticesinde sırasıyla dana, kuzu ve tavuk etleri için MAPE değerleri sırasıyla 2.4279, 1.2077 ve 1.424 iken ARIMA modelleri için ise MAPE değerleri sırasıyla 15.7521, 29.280 ve 10.3951 olarak elde edilmiştir.

İlgili yazıda, araştırmacılar MAPE değerinin %10'nun altında seyreden tahminlerin “yüksek doğruluk” seviyesinde, %10 ile %20 arasında seyreden modellerin “doğruluk” seviyesinde sınıflandırmışlardır (S.F. Witt ve C. Witt, 1992). Ayrıca Lewis, MAPE değeri %20 ile %50 arasında seyreden modelleri “kabul edilebilir” seviyede, son olarak ise %50 üzerinde MAPE değeri sunan modellerin ise “yanlış ve hatalı” olarak sınıflandırmıştır (Lewis, 1982; Çuhadar vd., 2009).

Uygulamalar neticesinde, yukarıdaki tabloların incelenmesiyle birlikte, yapay sinir ağı modellerinin ARIMA modellerinin tümünden daha az tahmin hatası gerçekleştirdiği saptanmıştır. Yukarıdaki tablolarda bulunan değerler kıyas edilerek, yapay sinir ağı

modelleri ile kurulan tahmin modellerinin geerli ve güvenilir olduėu sonucuna varılmıřtır.



7. SONUÇ VE ÖNERİLER

Bu çalışmada, nicel tahmin yöntemlerinden Yapay Sinir Ağları ile neden-sonuç ilişkisine dayalı tahmin çalışması gerçekleştirilmiştir. YSA modelleri üzerine araştırmalar yapılarak daha önce gerçekleştirilen tahmin modelleri incelenmiştir. Tahmin çalışmasının performansının değerlendirilmesi için zaman serisi modellerinden ARIMA modelleri ile kıyaslamalar gerçekleştirilmiştir. Bulunan tahmin değerlerinin gelecek ile alakalı önemli yönlendirmeler içerdiğinden, karar vericilerin farklı tahmin çalışmalarını göz önünde bulundurulması hedeflenerek literatürde en fazla yere sahip iki model olan YSA ve ARIMA modelleri kıyaslanmıştır. Daha önce yapılan çalışmaların incelenmesi ve bu tez çalışmasında elde edilen sonuçlar neticesinde Yapay Sinir Ağları ile kurulan tahmin modellerinin daha iyi tahmin performansı sunduğu gözlemlenmiştir.

Çalışmada incelenen 3 farklı et türü için de YSA modellerinin daha iyi performans sunması neticesinde, çalışmanın gerçekleştiği perakende mağazası için, tahmin modelleri 3 farklı et türü için de YSA modelleri ile oluşturulmuş ve ileriye dönük 7 haftalık talep tahmini gerçekleştirilmiştir. Bu çalışmanın ve elde edilen sonuçların başta çalışmanın gerçekleştiği firma olmak üzere, aynı sektörde faaliyet gösteren firmalara katkı sunacağı düşünülmektedir.

Gelecek çalışmalarda talebi dışarıdan etkileyen faktörlerin tespiti ve eklenmesinin ardından ARIMA ve yapay sinir ağları ile birlikte melez bir model ile daha iyi tahmin sonuçlarının alınacağı düşünülmektedir.

KAYNAKLAR

- Adıyaman, F., 2007. Talep Tahmininde Yapay Sinir Ağlarının Kullanılması. İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Aelemans, W., Hoste, V., De Meulder, F., Naudts, B., (2003). Combined Optimization of Feature Selection and Algorithm Parameters in Machine Learning of Language. In European on Machine Learning (Pp. 84-5). Springer, Berlin, Heidelberg.
- Ahamad, K. I., Akthar, S., 2016. Survey on Artificial Neural Network Learning Technique Algorithms. International Research Journal of Engineering and Technology, 3, 2.
- Amber, K.P., Khan, M.S., 2018. Intelligent Techniques for Forecasting Electricity Consumption of Buildings. Energy, 157, 886-893.
- Anand, A., Suganthi, L., 2018. Hybrid GA-PSO Optimization of Artificial Neural Network for Forecasting Electricity Demand. Energies, 11(4), 728-743.
- Anderson, S., 2003. Practical Business Forecasting. Evans, M.K. (Ed.), Blackwell Publishing, 246-255, Oxford, UK.
- Androutsopoulos, I., Paliouras, G., Karkaletsis, V., Sakkis, G., Spyropoulos, C.D., Stamatopoulos, P., 2000. Learning to Filter Spam E-Mail: a Comparison of a Naive Bayesian and a Memory Based Approach.
- Arasta., 1999. Dünyada Perakendecilik Nereye Gidiyor. Alışveriş Merkezleri ve Perakendecileri Derneği Dergisi, Kasım-Aralık, Sayı: 14 ,s. 14-20.
- Ateşoğlu, A. A., 2015. ARIMA ve Yapay Sinir Ağları (YSA) Kullanılarak Hibrit Tahmin Modeli Geliştirilmesi. Başkent Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara.
- Aydın, K., 1992. Perakendecilik ve Departmanlı Mağaza Müşterilerinin Sosyo-Ekonomik Özellikleri, Özgül Matbaası, İstanbul.
- Aydın, K., 2013. Perakende Yönetiminin Temelleri. Nobel Akademik Yayıncılık, 338, İstanbul.
- Ballot, M., 1986. Decision Making Model in Production & Operations Management. Robert E. Krieger Publishing Company, Florida.
- Baykal, N., Beyan, T., 2004. Bulanık Mantık Uzman Sistemler ve Denetleyiciler, Bıçaklar Kitabevi, Ankara.
- Belciug, S., Gorunescu, F., 2014. Error-Correction Learning for Artificial Neural Network Using The Bayesian Paradigm. Application to Automated Medical Diagnosis. Journal of Biomedical Informatics, 52, 329-337.
- Berman, B., Evans J.R., 2001. Retail Management: A Strategic Approach. PrenticeHall, 708, USA.

- Biçen, C., 2006. Box-Jenkins Zaman Serisi Analiz Yöntemi ile İleri Beslemeli Yapay Sinir Ağları Tahminlerinin Karşılaştırması. Hacettepe Üniversitesi, Sağlık Bilimleri Enstitüsü, Yayınlanmamış Yüksek Lisans Tezi, Ankara.
- Bircan, H., Karagöz, Y., 2003. Box-Jenkins Modelleri ile Aylık Döviz Kuru Tahmini Üzerine Bir Uygulama. Kocaeli Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 6(2), 49-62.
- Box, G.E., Jenkins, G.M., Reinsel, G.C., Ljung, G.M., 2016. Time Series Analysis: Forecasting and Control. Fifth Edition, John Wiley&Sons Inc. Hoboken, New Jersey, USA.
- Cengiz, E., Özden, B., 2003. Perakendecilikte Büyük Alışveriş Merkezleri ve Tüketicilerin Büyük Alışveriş Merkezleri İle İlgili Tutumlarını Tespit Etmeye Yönelik Bir Araştırma. Ege Akademik Bakış, Ege Üniversitesi İktisadi İdari Siyasi Bilimler Dergisi, Sayı 3.
- Chung, S., 2001. Demand Modeling and Analysis for The Management of Underground Infrastructure Systems. Purdue University, Doktora Tezi, USA.
- Çağlar, T., 2007. Talep Tahmininde Kullanılan Yöntemler ve Fens Teli Üretimi Yapan Bir İşletmede Uygulanması. Kırıkkale Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Kırıkkale.
- Çakmak, A. Ç., 2012. Ziyaretçilerin Alışveriş Merkezlerini Tercih Etme Nedenlerinin Araştırılması ve Karabük Şehir Merkezinde Bir Uygulama. Niğde Üniversitesi İİBF Dergisi, 195-215.
- Çuhadar, M., Kayacan, C., 2005. Yapay Sinir Ağları Kullanılarak Konaklama İşletmelerinde Doluluk Oranı Tahmini: Türkiye'deki Konaklama İşletmeleri Üzerinde Bir Deneme. Anatolia: Turizm Araştırmaları Dergisi, 16(1), 24-30.
- Davies, B., Ward, P., 2002. Managing retail consumption. Wardareboth of Cheltenham & Gloucester College of Higher Education, 370p, UK.
- Dawson, J., 2000. Retailing at centuryend: Some Challenges for Management and Research. The International Review of Retail, Distribution and Consumer Research 10 (2). Taylor & Francis, 119-48.
- Debnath, K.B., Mourshed, M., 2018. Forecasting Methods in Energy Planning Models. Renewable and Sustainable Energy Reviews, 88, 297-325.
- Donselaar, K.H., Peters, J., Jong, A., Broekmeulen, R.A.C.M., 2016. Analysis and Forecasting of Demand During Promotions for Perishable Items. International Journal of Production Economics, 172, 65-75.
- Durak, A., 2012. Konvektif Bir Kurutma Prosesinin Yapay Sinir Ağları ile Modellenmesi. Namık Kemal Üniversitesi, Yüksek Lisans Tezi, Tekirdağ
- Dündar, S., Ecer, F., Özdemir, Ş., 2007. Fuzzy Topsis Yöntemi ile Sanal Mağazaların Web Sitelerinin Değerlendirilmesi. İktisadi ve İdari Bilimler Dergisi, Cilt: 21, Sayı: 1. 289.

- Ekmekçi, H., “Türkiye’deki Doğalgaz Kullanımının ARIMA Metodu ile İstatistiksel Analizi, Yüksek Lisans Tezi, Karabük Üniversitesi, Karabük, 2006.
- Efendigil, T., 2008. Müşteri Odaklı Sistemler için Yapay Sinir Ağları ve Bulanık Çıkarım Tabanlı Karar Destek Sistemi Yaklaşımı, Doktora Tezi, Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü, İstanbul.
- Eren, U., Satoğlu, Ş.I., 2007. Perakende Giyim Sektöründe Yapay Sinir Ağları ile Talep Tahmini.
- Es, H.A., 2013. Yapay Sinir Ağları İle Türkiye Net Enerji Talep Tahmini. Gazi Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Ankara.
- Es, H.A., Kalender, F.Y., Hamzaçebi, C., 2014. Yapay Sinir Ağları ile Türkiye Net Enerji Talep Tahmini. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi, 29(3), 495-504.
- Gilbert, D., 1996. Retail Marketing Management. Pearson Education Limited, Great Britain.
- Gökcel, D., 2009. Perakende Sektöründe Kategori Bazlı Talep Tahmin ve Sipariş Sistemi uygulaması. Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Gözcü, O., 2009. Türkiye’de Hava Ulaşım Talebinin Arıma Modelleri ile Tahminlenmesi. Atatürk Üniversitesi. Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Erzurum.
- Gujarati, D. N., 2004. Basic Econometrics. Mcgraw- Hill Companies, Newyork.
- Halaç, O., 1995. Kantitatif Karar Verme Teknikleri. Alfa Basım Yayım Dağıtım, 580, İstanbul.
- Hamzaçebi, C., Kutay, F., 2004. Yapay Sinir Ağları ile Türkiye Elektrik Enerjisi Tüketiminin 2010 Yılına Kadar Tahmini. Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Derneği, 19(3), 227-233.
- Hanke, J.E., Wichern, D.W., 2009. Business forecasting. Ninth Edition, International Edition, Pearson Yayıncılık.
- Harr, S., R. I. D., “Using Cointegration Analysis in Econometric Modelling”, Printice Hall, Londra, 28 (1995).
- Hinton, G.E., Osindero, S., Teh, Y.W., (2006). A Fast Learning Algorithm for Deep Belief Nets. Neural Computation, 18 (7), 1527-1554.
- Hung, H., Tsai, T., Wu, M., 2014. A Modified Lotka-Volterra Model for Competition Forecasting in Taiwan’s Retail Industry. 77, 70-79.
- İslamoğlu, A. H., 2000. Pazarlama Yönetimi. Beta Basım, İstanbul.
- İslamoğlu, A. H., 2003. Tüketici Davranışları. Beta Yayınları, İstanbul.
- Jain, A. K., Mao, J., Mohiuddin, K.M., (1996). Artificial Neural Networks: A tutorial. Computer, 29(3), 31-44.

- Kahveciođlu, R., 1993. Süpermarketlerde Pazarlama Faaliyetleri ve Tüketicilerin Süpermarketleri Tercih Nedenleri ve Beklentileri. Anadolu Üniversitesi, Sosyal Bilimler Enstitüsü, Eskişehir.
- Kandanand, K., 2011. Forecasting Electricity Demand in Thailand with an Artificial Neural Network Approach. *Energies*, 4(8), 1246-1257.
- Karaatlı, M., Helvaciođlu, Ö.C., Ömürbek, N., Tokgöz, G., 2012. Yapay Sinir Ağları ile Otomobil Satış Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 8(17), 87-100.
- Karafakıođlu, M., 2005. Pazarlama İlkeleri. Literatür Yayıncılık, 336, İstanbul.
- Karahan, M., 2011, İstatistiksel Tahin Yöntemleri: Yapay Sinir Ağları Metodu ile Ürün Talep Tahmini Uygulaması, Selçuk Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Konya.
- Karahan, M., 2015. Forecasting Amount of Export Demand with Artificial Neural Networks Method: A Comparative Analysis of ARIMA and ANN. *Ege Akademik Bakış Dergisi*, 15(2), 165-172.
- Kaya, B.F., 2009. Perakendecilik Sektöründe Müşteri Memnuniyet Düzeyinin Belirlenmesi: İndirim Marketleri Üzerinde Bir Uygulama. Çukurova Üniversitesi, Sosyal Bilimleri Enstitüsü, Yüksek Lisans Tezi, Adana.
- Khalidi, R., Afia, A., Chibeb, R., 2019. Forecasting of Weekly Patient Visits to Emergency Department: Real Case Study. *Procedia Computer Science*, 532-541.
- Kılıç, F., Akkaya, M.R., Memili, N., 2018. Yemekhane için Yapay Zekâ Teknikleri Kullanımı ile Günlük Talep Tahmini. *Avrupa Bilim ve Teknoloji Dergisi*, 13, 65-71.
- Kızılaslan, R., 2008. Kısa ve Orta Vadeli İstanbul Doğalgaz Tüketiminin Yapay Sinir Algoritmaları ile Tahmin Edilmesi. Fatih Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Kiki, M., 2018. Price Forecasting Day-Ahead Turkey Electricity Market Using Artificial Neural Network. *Erzincan Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, Erzincan.*
- Kobu, B., 1994. Üretim Yönetimi. Avcıol Basım-Yayımları, 8. Baskı, İstanbul.
- Kohonen, T., Barna, G., (1987). Statistical Pattern Recognition with Neural Networks: Benchmarking Studies, *Proc. of The Int. Joint Conf. on Neural Networks*, 1: 1-66.
- Kotler, P., 2000. *Marketing Management. The Millennium Edition*, Northwestern University, Prentice Hall International, New Jersey, USA.
- Kotler, P., Armstrong, G., 2006. *Principles of Marketing. Global Edition*, New Jersey

- KPMG, 2018. Perakende Sektörel Bakış 2018. Erişim Tarihi: 11.01.2019. <https://assets.kpmg/content/dam/kpmg/tr/pdf/2018/01/sektorel-bakis-2018-perakende.pdf>
- Kutlar, A., 2007. Ekonometriye Giriş. Nobel Yayın Dağıtım, 1.Baskı, Ankara.
- Lewy, M., Weitz, B., Grewal, D., 2004. Retailing Management. McGraw-Hill Education, 2 Penn Plaza, New York.
- Makridakis, S., Wheelwright, S.C., Hyndman, R.J., 1998. Forecasting Methods and Applications. Third Edition, Wiley, Hoboken, New Jersey, USA.
- Manoj K., Madhu A., 2012. An Application Of Time Series ARIMA Forecasting Model for Predicting Sugarcane Production in India. Studies in Business and Economics, 9(1), 81-94.
- Masters, T., 1993. Practical Neural Network Recipes in C++. Academic Pres, USA.
- Monks, J.G., 1996. İşlemler Yönetimi Teori ve Problemler, Çev. Üreten S. Nobel Yayın Dağıtım, Ankara.
- Mou, S., Robb, D.J., DeHoratius, N., 2018. Retail Store Operations: Literature Review and Research Directions. European Journal of Operational Research, 265, 399-422.
- Mucuk, İ., 2012. Pazarlama İlkeleri. Türkmen Kitabevi, 432, İstanbul.
- Mucuk, İ., 2001. Pazarlama İlkeleri. Türkmen Kitabevi, 13. Basım, İstanbul.
- Murat, K., Dilbaz A.N., Bal T.S., 2013. Perakende Gıda Market Mağazacılığında Tüketici Talebi. Akademik Bakış Dergisi.
- Musaylh, M.S. Deo, R.C., Adamowski, J.F., Li, Y., 2018. Short-Term Electricity Demand Forecasting with MARS, SVR and ARIMA Models Using Aggregated Demand Data in Queensland, Australia. Advanced Engineering Informatics, 35, 1-16.
- Ohyver, M., Pudjihastuti, H., 2018. Arima Model for Forecasting the Price of Medium Quality Rice to Anticipate Price Fluctuations. Procedia Computer Science, 135, 707-711.
- Olgun, S., 2009. Tedarik Zinciri Yönetiminde Talep Tahmin Yöntemleri ve Yapay Zeka Tabanlı Bir Talep Tahmini Modelinin Uygulanması. İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, İstanbul.
- Özdemir, A.İ., 2004. Tedarik Zinciri Yönetiminin Gelişimi Süreçleri ve Yararları. Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, Sayı: 23, ss. 87-96.
- Özmen, A., Şıklar, E., Durucasu, H., Atlas M., Er, F., 2013. İstatistik II. Açıköğretim Anadolu Üniversitesi Yayınları, 1.Baskı, Eskişehir.
- Qu, T., Zhang, J.H., Chan, T.S., Srivastava, R.S., Tiwari, M.K., Park, W., 2017. Demand Prediction and Price Optimization for Semi-Luxury Supermarket Segment. Computers & Industrial Engineering, 113, 91-102.

- Rumelhart, D.E., Zipser, D., 1985. Feature Discovery by Competitive Learning. *Cognitive Science*, 9(1), 75-112.
- Schmit, T.M., Kaiser, H.M., 2006. Forecasting Fluid Milk and Cheese Demands for the Next Decade. *Journal of Dairy Science*, 89(12), 4924-4936.
- Solak, A.O., 2013. Türkiye'nin Toplam Petrol Talebi ve Ulaştırma Sektörü Petrol Talebinin ARIMA Modeli ile Tahmin Edilmesi. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(3), 131-142.
- Sun, Z., Choi, T., Au, K., Yu, Y., 2008. Sales Forecasting Using Extreme Learning Machine with Applications in Fashion Retailing. *Decision Support Systems*, 46 (1), 411-419.
- Şahin, E.E., 2018. Kripto Para Bitcoin: ARIMA ve Yapay Sinir Ağları ile Fiyat Tahmini. *Fiscaeconomia*, 2, 74-92.
- Şen, A.B., Kaba, G., 2009. Öncü Göstergeler Kullanımının Tahmin Doğruluğuna Etkisi: Türk Otomotiv Pazarı Üzerine Bir Araştırma. *Marmara Üniversitesi, İ.İ.B.F. Dergisi*, 28(2), 397-411.
- Şen, Z., (2004). Yapay Sinir Ağları İlkeleri. Su Vakfı Yayınları, İstanbul.
- ŞİRELİ, A.F., 1975. İmalatçılar Açısından Perakendeciliğin Mana ve Önemi. *Pazarlama Dergisi*, 12-17.
- Tanizaki, T., Hoshino, T., Shimmura, T., Takenaka, T., 2019. Demand Forecasting in Restaurants Using Machine Learning and Statistical Analysis. *Procedia CIRP*, 79, 679-683.
- Tanyaş, M., Baskak, M., 2008. Üretim Planlama ve Kontrol. İrfan Yayıncılık, 432, İstanbul.
- Tarı, Recep., 2010. Ekonometri. Umuttepe Yayınları, 6. Baskı, Kocaeli.
- Taşova, O., 2011. Yapay Sinir Ağları ile Yüz Tanıma. Dokuz Eylül Üniversitesi, Fen Bilimler Enstitüsü, Doktora Tezi, İzmir.
- Tek, B. Ö., 1997. Pazarlama ilkeleri. 7. baskı, İstanbul.
- Tek, Ö. B., 1999. Pazarlama İlkeleri: Global Yönetimsel Yaklaşım Türkiye Uygulaması, Betaş, 8.Baskı, İstanbul.
- Tek, Ö., Demirci O.F., 2006. Perakende Pazarlama Yönetimi. Birleşik Matbacılık, İzmir.
- Tek, Ö.B., 1984. Perakende Pazarlama Yönetimi. Üçel Yayıncılık, İzmir.
- Tekin, M., 2009. Üretim Yönetimi. Günay Ofset, Cilt 1, 6. Baskı, Konya.
- Turhan, C., Gökçen, G., Kazanasmaz, Z.T., 2013. Yapay Sinir Ağları ile İzmir'deki Çok Katlı Binaların Toplam Enerji Tüketimlerinin Tahmin Edilmesi. 11. Ulusal Tesisat Mühendisliği Kongresi ve Teskon+Sodex Fuarı Bildirileri, 17-20 Nisan, İzmir, 134: 61-68.

- Türk Dil Kurumu (TDK), 2019. Perakende Kelimesinin Anlamı. Erişim Tarihi: 07.01.2019. http://www.tdk.gov.tr/index.php?option=com_gts&kelime=PERAKENDE
- Türkiye İstatistik Kurumu (TÜİK), 2015. Yıllık Sanayi Hizmet İstatistikleri. Erişim Tarihi: 17.01.2019. <http://www.tuik.gov.tr/PreHaberBultenleri.do?id=21528>
- Ulucan, E., Kızılırmak, İ., 2018. Konaklama İşletmelerinde Talep Tahmin Yöntemleri: Yapay Sinir Ağları ile İlgili Bir Araştırma. Seyahat ve Otel İşletmeciliği Dergisi, 15(1), 89,101.
- Üreten, S., 2005. Üretim İşlemler Yönetimi Stratejik Kararlar ve Karar Modelleri. Gazi Kitabevi, 523, Ankara.
- Vandaele, W., 1983. Applied Time Series and Box-Jenkins Models. Academic Press Inc., 193 p, Florida, USA.
- Varinli, İ., Oyman, M., 2013. Perakendeciliğe Giriş. Anadolu Üniversitesi Yayınları, Eskişehir.
- Wang, Q., Li, S., Li, R., 2018. China's Dependency on Foreign Oil Will Exceed 80% by 2030: Developing a Novel NMGM-ARIMA to Forecast China's Foreign Oil Dependence from Two Dimensions. Energy, 163, 151-167.
- Wongsathan, R., Seeadan, I., 2016. A Hybrid ARIMA and Neural Networks Model for PM-10 Pollution Estimation: The Case of Chiang Mai City Moat Area. Procedia Computer Science, 86, 273-276.
- Yetkin, M., (2015). Tanker-şamandıra Bağlama Sistemlerinin Yapay Sinir Ağları Tekniğiyle Optimizasyonu.
- Yüksek, A.G., 2007. Hava Kirliliği Tahmininde Yapay Sinir Ağları ve Çoklu Regresyon. Cumhuriyet Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, Sivas.

ÖZGEÇMİŞ

Adı Soyadı : Muhammed Resul AYDIN
Doğum Yeri ve Yılı : ÜMRANİYE, 05/07/1992
Medeni Hali : Evli
Yabancı Dili : İngilizce
E-posta : mresulaydin@outlook.com



Eğitim Durumu

Lise : Erkut Soyak Lisesi
Lisans : Karabük Üniversitesi, Mühendislik Fakültesi, Endüstri Mühendisliği Bölümü
Yüksek Lisans : İstanbul Ticaret Üniversitesi, Fen Bilimleri Enstitüsü, Endüstri Mühendisliği Anabilim Dalı

Mesleki Deneyim

Kamalıoğlu Gıda ve Pazarlama Ltd. Şti (2016-devam ediyor)

Yayınları

Aydın, M.R., 2019. Yapay Sinir Ağları ile Talep Tahmini: Perakende Sektöründe Bir Uygulama. İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi, Bahar (Kabul Edildi).