

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**

**BELİRSİZ KOŞULLAR ALTINDA TALEP TAHMİNİ VE GIDA
İŞLETMESİNDE BİR UYGULAMA**

YÜKSEK LİSANS TEZİ

FEYZA ÇOBAN

DENİZLİ, 2019

**T.C.
PAMUKKALE ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI**



**BELİRSİZ KOŞULLAR ALTINDA TALEP TAHMİNİ VE GIDA
İŞLETMESİNDE BİR UYGULAMA**

YÜKSEK LİSANS TEZİ

FEYZA ÇOBAN

DENİZLİ, KASIM - 2019

KABUL VE ONAY SAYFASI

Feyza ÇOBAN tarafından hazırlanan "Belirsiz Koşullar Altında Talep Tahmini ve Gıda İşletmesinde Bir Uygulama" adlı tez çalışmasının savunma sınavı 15.11.2019 tarihinde yapılmış olup aşağıda verilen jüri tarafından oy birliği/oy çokluğu ile Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Endüstri Mühendisliği Anabilim Dalı Yüksek Lisans Tezi olarak kabul edilmiştir.

Jüri Üyeleri

İmza

Danışman

Dr. Öğr. Üyesi Leyla DEMİR



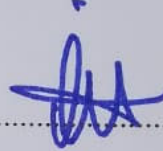
Üye

Doç.Dr. Hacer Güner GÖREN
Pamukkale Üniversitesi

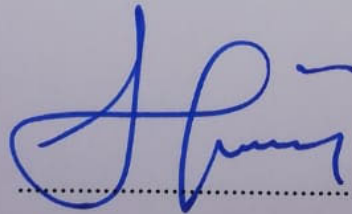


Üye

Doç.Dr. Ömür TOSUN
Akdeniz Üniversitesi



Pamukkale Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun
22/11/2019 tarih ve 67/09-2-2 sayılı kararıyla onaylanmıştır.



Prof. Dr. Uğur YÜCEL

Fen Bilimleri Enstitüsü Müdürü

BEYAN

Bu tezin tasarımı, hazırlanması, yürütülmesi, arařtırmalarının yapılması ve bulgularının analizlerinde bilimsel etięe ve akademik kurallara özenle riayet edildiđini; bu çalışmanın doğrudan birincil ürünü olmayan bulguların, verilerin ve materyallerin bilimsel etięe uygun olarak kaynak gösterildiđini ve alıntı yapılan çalışmalara atfedildiđine beyan ederim.

Feyza ÇOBAN



ÖZET

**BELİRSİZ KOŞULLAR ALTINDA TALEP TAHMİNİ VE GIDA
İŞLETMESİNDE BİR UYGULAMA
YÜKSEK LİSANS TEZİ
FEYZA ÇOBAN
PAMUKKALE ÜNİVERSİTESİ FEN BİLİMLERİ ENSTİTÜSÜ
ENDÜSTRİ MÜHENDİSLİĞİ ANABİLİM DALI
(TEZ DANIŞMANI: DR. ÖĞR. ÜYESİ LEYLA DEMİR)
DENİZLİ, KASIM - 2019**

Talep tahmini, bir ürün için gelecek dönemlerde oluşabilecek talebin geçmiş dönemlerdeki satış hareketlerine ait veriler kullanılarak belirlenmesidir. Bu çalışmada gıda sektöründeki bir işletmede belirsiz koşullar altında talep tahmini yapılmıştır. Belirsiz koşullar altında tahmin yapılırken geleneksel istatistiksel yöntemlerin yetersiz olması sebebiyle çalışmada yapay zekâ tekniklerinden Yapay Sinir Ağları (YSA) ve Destek Vektör Regresyonu (DVR) yöntemleri kullanılmıştır. Yöntemler uygulanmadan önce parametre optimizasyonu amacıyla deney tasarımı yapılmış ve bulunan optimum parametre değerleri ile tahmin gerçekleştirilmiştir. Yapılan tahminlerin performansı Ortalama Hata Kare, Ortalama Yüzde Hata ve Ortalama Mutlak Yüzde Hata gibi farklı hata ölçütlerine göre değerlendirilmiştir. Sayısal sonuçlar, incelenen ürünler için YSA'nın DVR'ye kıyasla daha iyi tahminler yaptığını göstermiştir.

ANAHTAR KELİMELELER: Talep Tahmini, Belirsizlik, Yapay Sinir Ağları (YSA), Destek Vektör Regresyonu (DVR)

ABSTRACT

DEMAND FORECASTING UNDER UNCERTAINTY AND AN APPLICATION IN A FOOD COMPANY

MSC THESIS

FEYZA OBAN

PAMUKKALE UNIVERSITY INSTITUTE OF SCIENCE

INDUSTRIAL ENGINEERING DEPARTMENT

(SUPERVISOR:DR. LEYLA DEMİR)

DENİZLİ, NOVEMBER 2019

Demand forecasting is the determination of the demand of a product that may occur in the future using the previous sales data. In this study, demand forecasting is carried out for a firm in food sector under uncertainty. It is well-known that the traditional statistical techniques are not sufficient while forecasting under uncertain conditions. Because of that Artificial Neural Networks (ANN) and Support Vector Regression (SVR) methods, which are the artificial intelligence techniques, are used in this study. Before employing these techniques, an experimental design is conducted for parameter optimization and forecasting is carried out with the optimum parameter values found. The performance of the forecasting is considering different criteria such as Mean Square Error, Mean Percentage Error and Mean Absolute Percentage Error. Numerical results showed that ANN produced better forecasts than SVR for considered products.

KEYWORDS: Demand Forecasting, Uncertainty, Artificial Neural Networks (ANN), Support Vector Regression (SVR)

İÇİNDEKİLER

Sayfa

ÖZET.....	i
ABSTRACT	ii
İÇİNDEKİLER	iii
ŞEKİL LİSTESİ	v
TABLO LİSTESİ	vi
KISALTMALAR LİSTESİ.....	vii
ÖNSÖZ.....	viii
1. GİRİŞ.....	1
2. TALEP TAHMİNİ VE TAHMİN YÖNTEMLERİ.....	3
2.1 Talep Tahminin Tanımı.....	3
2.2 Tahmin Yöntemlerinin Sınıflandırılması.....	5
2.2.1 Nitel Yöntemler	5
2.2.2 Nicel Yöntemler.....	6
2.2.2.1 Zaman Serileri Analizi	6
2.2.2.2 Nedensel Yöntemler.....	6
2.2.2.3 Yapay Zekâ Tabanlı Yöntemler	7
3. BELİRSİZLİK KAVRAMI.....	8
3.1 Belirsizliğin Tanımı	8
3.2 Literatürde Belirsizlik Olgusu	8
3.3 Talep Tahmininde Belirsizlik Olgusu	10
3.3.1 Doğrusallık.....	10
3.3.2 Trend	11
3.3.3 Mevsimsellik Analizi	11
3.3.4 Mevsimsel Trend.....	11
4. LİTERATÜR ARAŞTIRMASI.....	12
5. YAPAY SİNİR AĞLARI VE DESTEK VEKTÖR REGRESYONU....	20
5.1 Yapay Sinir Ağları.....	20
5.1.1 Yapay Sinir Ağlarının Yapısı ve Elemanları	20
5.1.1.1 Biyolojik Sinir Hücresi	20
5.1.1.2 Yapay Sinir Hücresi	22
5.1.1.2.1 Girdiler.....	22
5.1.1.2.2 Ağırlıklar.....	22
5.1.1.2.3 Toplama Fonksiyonu	22
5.1.1.2.4 Aktivasyon Fonksiyonu	22
5.1.1.2.5 Çıktılar	22
5.1.2 Yapay Sinir Ağlarının Özellikleri.....	23
5.1.3 Yapay Sinir Ağlarının Sınıflandırılması	24
5.1.3.1 Bağlantı Yapılarına Göre Ağlar	25
5.1.3.1.1 İleri Beslemeli Ağlar.....	25
5.1.3.1.2 Geri Beslemeli Ağlar	25
5.1.3.2 Öğrenmelerine Göre Ağlar.....	26
5.1.3.2.1 Danışmanlı Ağlar.....	26

5.1.3.2.2	Karma Stratejiler.....	26
5.1.3.2.3	Takviyeli Ağlar.....	26
5.1.3.2.4	Danışmansız Ağlar.....	27
5.1.3.3	Zamanına Göre Ağlar.....	27
5.1.4	Yapay Sinir Ağı Modelleri.....	27
5.1.4.1	Tek Katmanlı Algılayıcılar.....	27
5.1.4.1.1	Basit Algılayıcı.....	28
5.1.4.1.2	Adaline.....	28
5.1.4.1.3	Madaline.....	28
5.1.4.2	Çok Katmanlı Algılayıcılar.....	29
5.1.4.2.1	İleriye Doğru Hesaplama.....	30
5.1.4.2.2	Geriye Doğru Hesaplama.....	32
5.2	Destek Vektör Algoritmaları.....	34
5.2.1	Destek Vektör Makineleri.....	34
5.2.2	Destek Vektör Regresyonu.....	37
5.2.2.1	Doğrusal Destek Vektör Regresyonu.....	37
5.2.2.2	Doğrusal Olmayan Destek Vektör Regresyonu.....	40
6.	UYGULAMA.....	42
6.1	Veri Seti.....	42
6.2	Verilerin Trend ve Mevsimsellik Analizi.....	43
6.3	Yapay Sinir Ağları ile Tahmin Çalışması.....	45
6.3.1	Parametre Optimizasyonu.....	46
6.3.2	YSA Sonuçları.....	48
6.4	Destek Vektör Regresyonu ile Tahmin Çalışması.....	52
7.	SONUÇ VE ÖNERİLER.....	56
8.	KAYNAKLAR.....	57
9.	ÖZGEÇMİŞ.....	62

ŞEKİL LİSTESİ

Sayfa

Şekil 5.1: Biyolojik sinir hücresi yapısı ve yapay sinir ağı yapısı (Maltarollo ve diğ.2013).....	21
Şekil 5.2: Yapay Sinir Ağlarının sınıflandırılması (Öztemel 2012)	24
Şekil 5.3: İleri beslemeli Yapay Sinir Ağları (Uslu 2016)	25
Şekil 5.4: Geri beslemeli Yapay Sinir Ağları (Uslu 2016)	26
Şekil 5.5: Tek katmanlı algılayıcının yapısı	28
Şekil 5.6: Çok katmanlı algılayıcının yapısı (Öztemel 2012)	30
Şekil 5.7: Doğrusal ayrılabilme durumunda ayırıcı düzlem (Özkan 2008)	35
Şekil 5.8: Doğrusal ayrılamama durumunda doğrusal olmayan ayırıcı düzlem (Özkan 2008)	36
Şekil 5.9: Doğrusal regresyon için ϵ değeri (Erdoğan 2019)	38
Şekil 5.10: Doğrusal regresyon için ϵ değeri ve esneklik değişkeni (Erdoğan 2019)	38
Şekil 5.11: Doğrusal olmayan regresyon için ϵ değeri (Erdoğan 2019)	40
Şekil 6.1: Ürün 1'e ait gerçekleşen satış miktarları	43
Şekil 6.2: Ürün 2'ye ait gerçekleşen satış miktarları.....	43
Şekil 6.3: Ürün 3'e ait gerçekleşen satış miktarları	44
Şekil 6.4: Ürün 4'e ait gerçekleşen satış miktarları	44
Şekil 6.5: Çalışmada kullanılan Yapay Sinir Ağı modeli	45
Şekil 6.6: Ürün 1 için regresyon grafiği	48
Şekil 6.7: Ürün 2 için regresyon grafiği	49
Şekil 6.8: Ürün 3 için regresyon grafiği	50
Şekil 6.9: Ürün 4 için regresyon grafiği	51
Şekil 6.10: Gerçekleşen ve tahmin edilen satış miktarları-Ürün 1	54
Şekil 6.11: Gerçekleşen ve tahmin edilen satış miktarları-Ürün 2	54
Şekil 6.12: Gerçekleşen ve tahmin edilen satış miktarları-Ürün 3	54
Şekil 6.13: Gerçekleşen ve tahmin edilen satış miktarları-Ürün 4	55

TABLO LİSTESİ

Sayfa

Tablo 4.1: Literatür araştırması	13
Tablo 5.1: Biyolojik sinir sistemi elemanları ve ona karşı gelen yapay sinir ağı elemanları.....	21
Tablo 5.2: Aktivasyon fonksiyonu örnekleri.....	23
Tablo 6.1: Ürünlerin geçmiş satış miktarlarına ait istatistik değerler	42
Tablo 6.2: Deney tasarımı kapsamında kullanılan parametreler	47
Tablo 6.3: En iyi parametre değerleri	47
Tablo 6.4: YSA ile yapılan tahminlere ait hata değerleri	51
Tablo 6.5: Deney tasarımında kullanılan parametreler ve değerleri	52
Tablo 6.6: En iyi parametre değerleri	52
Tablo 6.7: DVR ile yapılan tahminlere ait hata değerleri	53
Tablo 6.8: Ürün bazında tahmin hataları: Yöntemlerin karşılaştırılması	53

KISALTMALAR LİSTESİ

- ÇKA : Çok Katmanlı Algılayıcı (Multi Layer Perceptron-MLP)
- DVM : Destek Vektör Makineleri (Support Vector Machines-SVM)
- DVR : Destek Vektör Regresyonu (Support Vector Regression-SVR)
- KOHK : Kök Ortalama Hata Kare (Root Mean Square Error-RMSE)
- LM : Levenberg Marquardt
- OHK : Ortalama Hata Kare (Mean Square Error-MSE)
- OMH : Ortalama Mutlak Hata (Mean Absolute Error-MAE)
- YSA : Yapay Sinir Ağları (Artificial Neural Networks-ANN)

ÖNSÖZ

Çalışma sürecime daha başlamadan yol göstericiliği yapan ve çalışmam boyunca her türlü desteği gösteren ve akademik anlamda kendimi geliştirmemde ve her anlamda yanımda olan, desteğini esirgemeyen danışmanım Sayın. Dr. Öğr. Üyesi Leyla DEMİR'e teşekkürü borç bilirim.

Ayrıca kendimi geliştirmem için bana hayatım boyunca bütün imkanları sağlayan ve her an yanımda olup bana destek olan aileme sonsuz teşekkürlerimi sunarım.

Çalışma sürecimde bana yardımcı olan İlhan SAĞER'e,

Ve son olarak çalışma sürecimde katkısı bulunan firma ve birey olarak yanımda olan arkadaşlarıma teşekkürlerimi sunarım.

1. GİRİŞ

Gelişen, değişen ve küreselleşen dünya koşulları ile birlikte artan teknoloji insan ihtiyaçlarında büyük değişimlere sebep olmuştur. Teknolojideki hızlı gelişmeler hemen hemen her sektörde hızlı ve değişken talep olgusunu doğurmuştur. Değişken talep olgusu sadece miktarda değil ürün çeşitliliğinde de bir artış meydana getirmiştir. Teknolojide ve piyasa koşullarında meydana gelen bu değişimler firmaları rekabet etmeleri için daha etkin stratejiler üretmeye zorlamış ve zorlamaya da devam etmektedir.

Pazarda meydana gelen hızlı değişimlere ayak uydurabilmenin ve firmaların rekabet üstünlüklerini koruyabilmelerinin ilk şartı piyasa koşullarını gözeterek stratejik planlar yapabilmekten geçmektedir. İyi bir planlama yapmanın birincil koşulu ise geleceğe dair güçlü öngörülerde bulunabilmektir. Yani planların iyi yapılmış tahminlere dayandırılmasıdır. Talep tahmini yapılırken genellikle işletmelerin geçmiş satış verileri mevsimsellik ve belirli bir trend gösterip göstermediklerine bakılarak analiz edilip, daha sonra istatistiksel yöntemlerle gelecekte oluşabilecek satış miktarları belirlenmektedir. Bu süreç yürütülürken uzmanların görüşleri de dikkate alınmaktadır. Ancak değişkenliğin ve belirsizliğin fazla olduğu durumlarda geleneksel tahmin yöntemleri yetersiz kalabilmektedir. Bu gibi durumlarda yapay zekâ teknikleri gibi öğrenmeye dayalı algoritmalar geleneksel yöntemlere göre çok daha iyi sonuçlar vermektedir. Özellikle değişkenliğin fazla olduğu ve satışların herhangi bir trendi takip etmediği durumlarda yapay zekâ teknikleri ile oldukça başarılı tahminler yapmak mümkün olmaktadır.

Bu çalışmada talebin hızlı bir şekilde değiştiği ve ürün çeşitliliğinin çok olduğu hazır gıda sektöründe talep tahmini çalışması yapılmıştır. Gıda sektöründe değişimin hızlı, kısıtların fazla olması ve üretimin çok boyutlu ve dinamik olması belirsizliği de beraberinde getirmektedir. Ürünlerin raf ömrü, yasal kısıtlamalar, üretimin her aşamasında test ve analizlerin fazlalığı ve dolayısıyla üretimi durdurabilecek sebeplerle beraber paket bozulması, ürün taşıma şartlarının değişmesi gibi lojistik riskler de gıda sektöründe belirsizliği artıran nedenlerdir. Bu

belirsizlikler ve talepteki hızlı deęişkenlik de gıda sektöründe yer alan işletmeler için talep tahminini zorlaştırmaktadır.

Belirsiz koşullar altında talep tahmini yapılırken regresyon analizi, üstel düzeltme gibi klasik yöntemler yerine, belirsizliği de dikkate alabilecek yöntemlerin uygulanması daha doğru tahminler yapılmasını sağlamaktadır. O nedenle bu çalışmada, belirsiz koşullar altında talep tahmini için Yapay Sinir Ağları (YSA) ve Destek Vektör Regresyonu (DVR) yöntemleri kullanılmış ve uygulanan yöntemler belirli hata kriterleri göz önünde bulundurularak karşılaştırılmıştır.

Tezin organizasyonu şu şekildedir: Çalışmanın ikinci bölümünde talep ve talep tahmini olgusuna değinilmiştir. Üçüncü bölümde belirsizlik ve belirsiz koşullar altında talep tahmini konusu ele alınmıştır. Dördüncü bölümde talep tahmini konusunda yapılan çalışmaların analiz edildiği ayrıntılı bir literatür taraması sunulmuştur. Beşinci bölümde çalışmada kullanılan teknikler olan Yapay Sinir Ağları ve Destek Vektör Regresyonu yöntemleri anlatılmıştır. Altıncı bölümde gerçekleştirilmiş olan uygulamanın ayrıntılarına yer verilmiş ve sonuçlar detaylı olarak analiz edilmiştir. Yedinci ve son bölümde ise yapılan çalışma özetlenerek gelecekte yapılabilecek çalışma önerileri sunulmuştur.

2. TALEP TAHMİNİ VE TAHMİN YÖNTEMLERİ

2.1 Talep Tahminin Tanımı

Talep, tüketicilerin herhangi bir ürün veya hizmeti satın alma isteğidir. Ekonomik olarak talep oluşabilmesi için tüketicilerin belirli bir fiyattan satın alabilme gücüne sahip olmaları gerekmektedir. Talebe etki eden faktörler; ürün veya hizmetin maddi tutarı, tüketicilerin satın alma gücü, ihtiyacın gereklilik durumu, tüketici alışkanlıkları ve çevresel etmenler olarak sıralanabilir (Zontul ve Yangın 2017). Tahmin genel olarak geçmişteki durumlar incelenerek geleceğin kestirilebilmesidir.

Talep tahmini, öngörüye dayalı işletme kararlarının oluşması açısından önem taşımaktadır. Bir ürünün gelecek dönemde nasıl bir satış durumuna sahip olabileceğinin geçmiş dönemlerdeki satış hareketlerine ait veriler incelenerek analiz edildiği süreç, talep tahmini olarak adlandırılmaktadır.

Talep tahmininde kantitatif (nicel), kalitatif (nitel) ve yapay zekâ tabanlı üç farklı yöntem kullanılmaktadır. Kantitatif yöntemler istatistiksel ve matematiksel verilere, kalitatif yöntemler ise kişisel çıkarım ve deneyimlere bağlı tahmin yürütme yöntemleridir. Klasik yöntemlerle (kantitatif ve kalitatif) çözümlenemeyen durumlarda, karmaşık veri yapılarını çözebilen yapay zekâ tabanlı yöntemler talep tahmininde sıklıkla kullanılmaktadır (Olgun 2009).

Talep tahmin yönteminin belirlenmesinde, tahminlerin kapsamakta olduğu zaman zarfı, tahminin yapılması için ayrılan süre, verilere ulaşılabilme durumu, tahmin sürecinde kullanılacak olan kaynakların maliyeti, tekniğin anlaşılabilirliği ve uygulanabilirliği, yöntemi uygulayacak ve tahminleri kullanacak kişilerin özellikleri gibi birçok değişken göz önünde bulundurulmalıdır (Serttaş 2011).

Talep tahminleri genellikle kısa süreli, orta süreli ve uzun süreli tahminler olarak dört dönem için yapılmaktadır. Günlük veya haftalık yapılan tahminler çok kısa süreli tahminlerdir. Stokların kontrolü, günlük üretim planının hazırlanması ve

sipariş verilmesi amacıyla yapılmaktadır. Bir hafta ile altı aylık süre aralığı için yapılan tahminler kısa süreli tahminlerdir. İşletmelerin malzeme ve makine kapasitesi ve işgücünün verimli kullanımı gibi düzenlemelerde kullanılırlar. Altı ay ile beş yıllık süre aralığı için yapılan tahminler orta süreli tahminlerdir. Tedarik sürecinin belirsizlik içerdiği satın almaların planlanması için uygundur. Beş yıl ve daha fazla zaman süreci için yapılan tahminler uzun süreli tahminlerdir. Genel olarak yeni yatırımlar öncesinde bu tahminlerin yapılması gerekir.

Talep tahmininde dikkat edilmesi gereken hususlar şunlardır:

- ✓ Miktar ve çeşitlilik olarak zengin olan ürünler açısından tahmin yapılması daha uygundur.
- ✓ Çok kısa ve kısa dönemli tahminlerin tutarlılık oranları daha yüksektir.
- ✓ Tahmin yöntemi uygulanmadan önce performansın test edilmesi gerekmektedir.
- ✓ Tahmin hiçbir zaman kesinleşmiş talebi karşılamaz.

Talep tahmini 5 aşamada gerçekleştirilir:

1. Talebi Etkileyen Unsurların Belirlenmesi: Tahmin öncesinde firmanın, tahmin yapılacak olan ürünün özellikleri, firmanın durumu, hedefleri, aynı ürüne yönelik rakip firmaların piyasada bulunuşları, ülkenin ekonomik durumu, yeni teknolojik gelişmeler gibi hususların belirlenmesi gerekir. Bu ürünlere yönelik talep ağırlığının ne olduğu belirlenmelidir.

2. Verilerin Toplanması: Tahmin üzerinde etki yaratabilecek faktörlerin belirlenmesi ve faktörlere yönelik verilerin toplanması, yapılacak tahmin çalışmasının en önemli evrelerindedir. Tahmin yönteminin belirlenmesinde kullanılacak veriler, firmanın önceki dönemlere yönelik durumları olabileceği gibi önceden oluşturulmuş istatistik veriler veya ülke ekonomisine yönelik istatistik veriler olabilir.

3. Talep Tahmin Döneminin Belirlenmesi: Talep tahmini yapılması planlanan zaman diliminin tespit edilmesidir. Bu zaman dilimde talep tahmini çalışması yapılır.

4. Talep Tahmin Yönteminin Seçimi ve Hata Oranının Hesaplanması:

Talep araştırmasında ulaşılmak istenen performans düzeyine göre tahmin yöntemi belirlenmelidir. Ayrıntılı talep araştırması gereken durumlarda, derinlemesine inceleme yapmaya uygun olmayan yöntemlerin kullanılması, istenilen sonuçlara ulaşılmasına engel olur. Bir tahminin doğruluğu, tahmin edilen değerler ile gerçekleşen değerler arasındaki farkla belirlenir. Bu fark tahmin yönteminin hata oranı olarak isimlendirilir.

5. Tahmin Sonuçlarının Geçerliliğinin Araştırılması: Belirlenen tahmin sonucu ile gerçek değerler arasındaki farkın tahmin edilmesi ve bu farklılığın neden oluştuğunun araştırılması sürecidir.

2.2 Tahmin Yöntemlerinin Sınıflandırılması

Tahmin yöntemleri kendi içinde nitel ve nicel yöntemler olmak üzere iki sınıfa ayrılmaktadır. Nitel yöntemlerin kullanımı daha çok uzman görüşlerine ve sözel verilere dayanmaktadır. Nicel yöntemler ise daha çok matematik ve analiz yöntemiyle hesaplamalara dayanmaktadır.

2.2.1 Nitel Yöntemler

Nitel yöntemlerle yapılan tahminlerde matematiksel veriler yerine görüşler ve hissi yargılar kullanılmaktadır. Tahminlerde hiçbir matematiksel hesaplama kullanılmadığı için yapılan tahminlerin güvenilirliği ve performansı diğer yöntemlere göre düşüktür (Olgun 2009).

Kullanılacak olan yöntemin nitel bir yöntem olması için öncelikle yeterli bir veri topluluğunun oluşturulamamış olması ve elde edilen verilerin analizi için yeterli zamanın bulunmaması gerekir. Bu yöntemleri diğer yöntemlerden ayıran en büyük avantaj yöntemde uygulayıcıların yargılarının ve hissiyatının kullanılabilmesidir.

Nitel tahmin yönteminde tahmin yapacak olan kişinin işletmedeki tecrübesi ve konuya olan uzmanlığı son derece önem teşkil etmektedir. Tahmin işlemi duygusal verilere ve kişisel görüşlere dayalı olacağı için doğruluğu hakkında

yorumlama yapılması oldukça güç olmaktadır. Aşağıda sıralanan yöntemler tahmin yapmak için kullanılabilir nitelikte yöntemlere örnek olarak verilebilir:

- Uzman Görüşünün Alınması
- Delphi Tekniği
- Anket Yöntemi
- Senaryo Analizi
- Satış Gücü Birleşimi

2.2.2 Nicel Yöntemler

Nicel tahmin yöntemleri geçmişte elde edilen verilerin matematiksel olarak işlenerek geleceğe ait tahminlerin ortaya konmasını amaçlayan yöntemlerdir. Geçmiş ve şimdiki satışlardan elde edilen veriler doğrultusunda satış etkileyen etkenlerin gelecek satışları da etkileyeceği düşünülerek tahmin yapılmaktadır. Matematiksel olarak geçmiş yılların satışları ile bu satışları etkileyen nedenler arasında bir ilişki kurmak suretiyle gelecek dönemler için satış tahmini yapılır. Kullanılan yöntemler üç bölüme ayrılmaktadır. Bunlar zaman serileri analizi, nedensel yöntemler ve yapay zekâ yöntemleridir.

2.2.2.1 Zaman Serileri Analizi

Zaman serileri tekniğinde geçmiş satış bilgileri analiz edilerek eldeki verilerin aylar veya yıllar bazında belirli bir trend gösterip göstermediği ve verilerin mevsimsellik içerip içermediği belirlenmeye çalışılır. Bu analizin yapılabilmesi için gerekli olan bilgi sıraya konulmuş geçmiş dönemlere ait istatistiksel verilerdir. Geçmiş veriler incelenerek bir model oluşturulur. Oluşturulan model doğrultusunda gelecek için tahminlerde ve varsayımlarda bulunulur.

2.2.2.2 Nedensel Yöntemler

Nedensel yöntemler, tahmin edilmek istenen bilgiyi etkileyen etmenlerin aralarındaki bağları inceleyerek, bu etmenler ve tahmin edilecek bilgiye ait değerler arasında ilişki kurmak suretiyle tahmin yaparlar. Nedensel yöntemlerin tek amacı gelecekle ilgili tahmin yapmak değildir. Aynı zamanda tahmini etkileyen faktörler bütünü inceleyerek, faktörler arasındaki bağ yapısını ve etkilenme düzeyini tespit

etmektedir. Nedensel yöntemler arasında en fazla kullanılan teknikler regresyon ve korelasyon analizleridir.

1. Regresyon analizi: Analizin temeli bağımlı değişkenlerin hesaplanmasında bir veya birden fazla değişkenin etkisinin ölçülmesine olanak sağlamasıdır. Kullanılan teknikte bir bağımlı değişken kullanılırsa tek değişkenli regresyon analizi, birden fazla değişken söz konusu ise çok değişkenli regresyon analizi olarak isimlendirilmektedir.

2. Korelasyon analizi: Analizin temeli, tahmini etkileyen değişkenlerin değerlendirilmesi ve aralarında bir ilişki varsa eğer bunun tespit edilmesidir. Tahmini etkileyen iki değişken arasında bir bağ bulunuyorsa bu iki değişken arasında korelasyon vardır denir. Korelasyon analizi değişkenler arasındaki ilişkiyel eğrinin değerlerinin bulunmasıdır.

2.2.2.3 Yapay Zekâ Tabanlı Yöntemler

Yapay zekânın temeli bilgisayarın insan gibi düşünerek problemlere çözüm yolları bulabilmesine olanak sağlamasıdır. Yapay zekâ kullanan yöntemler genel anlamda çok yönlü ve çok fazla ilişki bulunduran problemlerin çözümünde iyi sonuç vermektedir. Yapay zekâ yöntemlerinin başında yapay sinir ağları gelmektedir. Son yıllarda Destek Vektör Makineleri (DVM) de tahmin problemlerini çözmeye sıklıkla kullanılan yöntemler arasında yer almaktadır. Bu tez çalışması kapsamında bahsi geçen iki yöntem kullanılarak tahmin performansları karşılaştırılmıştır. Yöntemlerin ayrıntıları beşinci bölümde verilmektedir.

3. BELİRSİZLİK KAVRAMI

Bu bölümde tez çalışmasının kapsamı dahilinde belirsizlik olgusuna değinilmiştir. Önce belirsizliğin tanımı verilmiş daha sonra belirsizliğin talep tahmini üzerindeki etkileri anlatılmıştır.

3.1 Belirsizliğin Tanımı

Belirsizlik kavramı sözlük anlamı olarak bir süreç içerisinde sonucu kesin olarak kestirememeye durumudur. Mühendislikte ise bu kavram süreç sonunda gerçekleşecek değerlerin istatistik ve yardımcı matematiksel çalışmalarla kestirilememesini ifade eder. En sık yapılan hata belirsizlik ve risk kavramlarının karıştırılmasıdır. Belirsizlik olumlu veya olumsuz gerçekleşebilecek sonuçların kestirilememesini ifade ederken risk ise meydana gelebilecek kestirilen veya kestirilemeyen olumsuz sonuçları ifade eder.

3.2 Literatürde Belirsizlik Olgusu

Tahminde olası sonuç değişkenlerinin ve varsayımlarının tamamının bilinmesinin mümkün olmaması belirsizlik olarak tanımlanır (Runde 1998). Olayın sonuçlarıyla ilgili bilgi eksiklerinin bulunduğu ve sonuçların belirli bir liste içinde bulunmadığı durumlarda belirsizlik ön plandadır (Lavoie 1994). Belirsizlikte, olayın sonuçlarının beklendiği biçimde olmaması sürpriz, sonuçların tahmin edilmesi için hiçbir veri ve hesaplamanın bulunmaması ise bilgisizlik olarak nitelendirilmektedir. Belirsizlik sürpriz etkisinin ortaya çıkmasıyla anlaşılan ve olayın sonuçlarının yorumlanması ile temel biçim kazanmaktadır (Bakımlı 2004). Belirsizlik durumu bireyin karar verme duygusu üzerinde son derece etkili bir duygudur. Belirsizliğin fazla olması neticesinde kişi karar vermekte zorlanmakta veya kararını ileri bir tarihe ertelemektedir. Bu durum istemli veya istemsiz olarak belirsizliğe bir tepki durumudur (Alada 2000). Bazı belirsiz koşul çalışmalarında veriye ulaşmanın da bir maliyet yarattığı görülmüştür. Stigler (1961) yaptığı çalışmada yapay sinir ağları

yöntemi ile tahminde belirsizlik koşullarında bilgi arama ve bilgiye ulaşma maliyetine değinmiştir.

Taleplerde zamansal değişim, moda vb. akımların etkisi ve talep eğilimleri gibi çevresel faktörlerden kaynaklı belirsizlikler de literatürde sıklıkla yer bulmuştur. Dosi ve Egidi (1991) yaptıkları çalışmada teknolojideki yeniliklerin ve yeni buluşların en önemli çevresel belirsizlik kaynağı olduğunu belirtmişlerdir. Ayrıca tahmin sürecinde geleceğe ait bilgilerinin tamamına ulaşamaması, bilgilerde oluşacak anlık değişkenlerin fazlalığı, müşteri beklentilerinin değişkenlik göstermesi ve çevresel etmenlere yeterince ulaşamamasının tahmin alanında her daim belirsizlik yaratacağını ifade etmişlerdir.

Tahminde en çok sorun yaşanan konuların başında gelen belirsizlik kavramı işletmede bulunan eskimiş bilgilerin sorgulanmasına, müşteri memnuniyetinin sorgulanmasına, satış fiyatlarının gözden geçirilmesine, üretici ve tüketici olgusunda değişiklikler yapılmasına, tedarik işlemlerinin değişkenlik göstermesine ve ürün tercihlerinde oluşan değişkenliğe neden olmaktadır (Stigler 1961). Belirsizliğin ortadan kaldırılmasına yönelik yeni ürün denemeleri, olasılık hesaplamalarının yapılması, uzman kişilerin işe alınması, maliyet satış analizlerinin yapılması ve müşteri memnuniyetinin ve talep miktarının ölçülmesi gibi birçok işlem uygulamaya konulmaktadır.

Üretim planlama ve tedarik zincirinde yapılan tahmin çalışmalarında literatürde birçok farklı kategoride belirsizlik olgusu işlenmiştir. Literatür incelendiğinde belirsizlik çeşitleri temel olarak iki başlık altında toplanmıştır. Bunlar çevresel ve sistemsal belirsizliklerdir.

Sistemsal belirsizlik, firmanın üretim süreci içerisinde meydana gelen olaylardan kaynaklı ve firma içinde yapılacak çalışmalarla yok edilebilecek veya azaltılabilecek belirsizliklerdir.

Verim belirsizliği: Firmanın üretim sürecinde üretim kaynakları ve çalışma sistemi içerisinde gerçekleşen kayıplar ve bunların meydana getirdiği belirsizliklerdir. İyi bir geçmiş veri analizi ile önüne geçilebilmektedir. Genellikle metot analizi çalışmalarıyla indirgenmeye çalışılmaktadır.

Bekleme sürelerindeki belirsizlik: Firmanın üretim süreci içerisindeki genellikle iş değişim süreçlerinde meydana gelen ya da genel arıza ve/veya aksaklıklar ile ortaya çıkan kayıplar ve bunların neden olduğu belirsizlikleri ifade eder.

Üretim kalitesindeki belirsizlik: Ürün ve süreç kalitesinde istenenin ya da beklenenin dışında gerçekleşen durumların yarattığı belirsizliklerdir.

Üretim sürecindeki genel aksamalar ve belirsizlikler: Önceki maddelerde bahsedilen aksama ve kayıplar dışında oluşan süreç belirsizliklerini ifade eder.

Çevresel belirsizlikler ise yalnızca firma üretim süreçleri ile açıklanamayan dış süreçlerde meydana gelen belirsizliklerdir. Bu belirsizlikler tedarik süreçlerinde meydana gelen belirsizlikler, ekonomik belirsizlik ve talep belirsizliği olarak sıralanabilir.

Tedarik süreçlerinde meydana gelen belirsizlikler: Tedarik sürecindeki belirsizlikler firmanın üretim için gerekli hammadde, yarı mamul vb. ürünleri tedarik ederken karşılaştığı belirsizlikleri ifade eder.

Ekonomik belirsizlikler: Ekonomik belirsizlikler yerel ve küresel ölçekte ekonomide meydana gelen değişimlerin yarattığı belirsizliklerdir. Döviz kurlarında meydana gelen değişimler bu belirsizliğe örnek olarak gösterilebilir.

Talep belirsizliği: Piyasa koşullarında ürüne olan talebin miktarının değişmesi veya yeni ürün talebinin oluşması gibi belirsizliklerdir. Müşteri talebinin zaman içindeki değişimini ifade eder.

3.3 Talep Tahmininde Belirsizlik Olgusu

Talep tahmini çalışması geçmiş verileri kullanarak gelecekte oluşacak taleplerin belirlenmesini ifade eder. Geçmiş veriler istatistiksel ve matematiksel olgulara dayanarak analiz edilirler.

3.3.1 Doğrusallık

Geçmiş verilerin doğrusal bir yapı seyretmesi durumudur.

3.3.2 Trend

Gerçekleşmiş satışların veya geçmiş talebin belirli bir artış ya da azalış eğilimi göstermesini ifade eder. Genel olarak veriler bir artış ya da azalış eğilimi gösteriyorsa talepte artış/azalış yönünde bir trend söz konusudur yorumu yapılır.

3.3.3 Mevsimsellik Analizi

Trend ya da doğrusallık olgusunun olmadığı durumlarda bazı dönemlerin birbirini taklit ettiği gözlenebilir. Talepte kendini taklit etme durumu varsa bu durum mevsimsellik olarak adlandırılır. Dondurma satışlarının yaz mevsiminde artıp kış mevsiminde azalması bu durumun en tipik örneğidir.

3.3.4 Mevsimsel Trend

Başlıktan da anlaşılacağı üzere önceki bölümlerde anlatılan iki özel durumun birlikte gerçekleşmesidir. Yani belirli periyotta kendini taklit eden durumlarla beraber uzun vadede sürekli artış ya da azalışı ifade eder. Bir başka tabirle kendini taklit eden mevsimsel dönemler arasında trend olması yani her mevsimin öncesine göre artış ya da azalış göstermesidir.

Geçmiş veriler kullanılarak yapılan tahminlerde yukarıdaki olguların tespiti durumunda zaman serileri analizini kullanarak tahmin yapmak mümkündür. Eğer veri analizinde bu olgulara ait bir bulgu gözlenmiyorsa talepteki değişimin belirsiz olduğu sonucuna varılır. Bu durumda yapılan tahmine belirsizlik altında talep tahmini denir.

4. LİTERATÜR ARAŞTIRMASI

Talep tahmini uzun yıllardan beri üretim planlama alanında çalışan araştırmacılar için en çok çalışılan araştırma konularından biri olmuştur. 2006 yılında McCarthy ve diğ. (2006) satış tahmini üzerine 20 yıllık bir süreci kapsayan ayrıntılı bir literatür araştırması yapmışlardır. O günden bu yana bu alanda birçok çalışma yapılmıştır. Bu bölümde tez çalışmasının kapsamı dahilinde 2006 yılından sonra yapay zekâ teknikleri ile yapılan tahmin çalışmaları, belirsiz koşullar altında yapılmış çalışmalar ve gıda alanında yürütülmüş tahmin çalışmaları araştırılmış ve sistematik bir biçimde sınıflandırılmıştır. Sınıflandırma yapılırken çalışma alanı, tahmin yöntemi ve ulaşılan sonuçlar üzerinde durulmuştur (Tablo 4.1).

Mor ve diğ. (2019) bozulabilir ürünler grubundan olan süt ve süt ürünlerinde satış tahmini yaptıkları çalışmalarında farklı ürün grupları için Hareketli Ortalama, Regresyon, Çoklu Regresyon ve Holt-Winters modellerini kullanarak talep tahmininde bulunmuş ve elde ettikleri sonuçları yorumlamışlardır. Veri seti olarak bir süt ürünleri üretim işletmesinde pazarlama, satış ve satın alma gibi farklı birimlerden temin ettikleri 4 yıllık verileri kullanmışlardır. Çalışma sonucunda hareketli ortalama modelinin yüksek tahmin hatası nedeniyle süt ürünlerinin tahmini için makul bir tahmin yöntemi olmadığı görülmüştür.

Villegasa ve diğ. (2018) satış tahmininde model seçimi için DVM tabanlı bir model seçim yaklaşımı önermektedir. Model tahmini için herhangi bir kriteri göz önünde bulundurmak yerine her tahmin kaynağından en iyi modeli seçmek için bir DVM eğitilmiştir.

Petropoulos ve diğ. (2018), zaman serileri analizinde üç temel belirsizlik kaynağı (veri belirsizliği, model belirsizliği, parametre belirsizliği) üzerinde durmuş ve her bir belirsizlik kaynağı için zaman serileri tahmininde torbalamanın yararlarını araştırmışlardır. Guo ve diğ. (2017) çalışmalarında belirsizlik teorisi üzerine geliştirilmiş bir belirsiz doğrusal regresyon modeli önermişler ve bu modelle Çin'in gayrisafi milli hasıla değerini tahmin etmişlerdir.

Tablo 4.1: Literatür araştırması

YAYIN YILI	YAZAR ADI	KULLANILAN YÖNTEM	ÇALIŞMA ALANI	ULAŞILAN SONUÇ
2019	Mor ve diğ.	Hareketli ortalama, Regresyon, Çoklu Regresyon, Holt Winters	Süt ürünleri satış tahmini	Süt ürünleri üreten bir işletmede farklı ürünler için yapılan satış tahmininde ürün gruplarına göre farklı modellerin uygun olduğu tespit edilmiştir. Buna göre Çoklu regresyon modeli ve Holt Winters modeli uygun sonuçlar verirken, Hareketli ortalama modeli hiçbir ürünün tahmini için uygun görülmemiştir.
2018	Villegasa ve diğ.	DVM	Tahmin modeli seçimi	Satış tahmini modeli seçimi için DVM tabanlı bir model önerilmiştir. Önerilen yöntem en uygun modelin seçimini yaparak en yüksek doğrulukta tahmin sonuçlarını vermiştir.
2018	Petropoulos ve diğ.	Torbalama tekniği	Zaman serileri analizinde belirsizlik	Zaman serileri analizindeki üç temel belirsizlik kaynağı üzerinde durularak önerilen torbalama tekniğinin uygun olduğu sonucuna varılmıştır.
2017	Guo ve diğ.	Belirsiz doğrusal regresyon modeli	Çin gayrisafi yurtiçi hasıla değeri tahmini	Çalışmada belirsiz koşullara özgü olarak geliştirilen belirsiz doğrusal regresyon modeli ile Çin'in gayrisafi yurtiçi hasıla değeri tahmin edilmiştir.
2016	Tabrizi ve Ghaderi	ARIMA, Yerel doğrusal nöro-bulanık model	Süt ve süt ürünleri fabrikasında satış tahmini	Önerilen yerel doğrusal nöro-bulanık modelin daha iyi performans gösterdiği görülmüştür.
2015	Raju ve diğ.	Temel Bileşenler Analizi	Küçük ölçekli işletmelerde süt talep tahmini	Değişkenlik faktörlerinin analizi yapılarak bu faktörlerin talep tahmini ile ilişkili olup olmadığı belirlenmiş ve bu bilgiler ışığında talep tahmini çalışması yapılmıştır.
2015	Parimita ve Arora	Saf model, hareketli ortalama modeli, üstel düzleştirme, nedensel yöntemler	Süt ve süt ürünleri fabrikasında satış tahmini	Tahmin yöntemlerinin performansının ürün gruplarına göre değişkenlik gösterdiği görülmüştür.

*ARIMA: Otoregresif Bütünleşik Hareketli Ortalama (Autoregressive Integrated Moving Average)

Tablo 4.2: Literatür araştırması (devam)

YAYIN YILI	YAZAR ADI	KULLANILAN YÖNTEM	ÇALIŞMA ALANI	ULAŞILAN SONUÇ
2014	Veiga ve diğ.	ARIMA, Holt-Winters	Süt ürünleri işletmesinde talep tahmini	Holt Winters metodunun daha iyi tahmin sonuçları verdiği, daha basit ve anlaşılır olduğu görülmüş fakat uzun dönemli tahminlerde başarısının düştüğü gözlenmiştir.
2014	Murphy ve diğ.	Dış girişli doğrusal olmayan oto-regresif model, Statik yapay sinir ağları, Çoklu doğrusal regresyon	Süt çiftliğinde üretilen çiğ süt verimi tahmini	Yapılan çalışmada dış girişli doğrusal olmayan oto-regresif model daha başarılı bulunmuş, ilerleyen çalışmalarda daha fazla süt üretim çiftliğinde farklı girdi faktörleri kullanılarak çalışmaların geliştirilmesi önerilmiştir.
2014	Jaipuria ve Mahapatra	Ayrık Dalgacık Dönüşümleri ve YSA tabanlı bütünlük bir yaklaşım, ARIMA	Otomotiv yedek parça, çimento ve çelik endüstrisi için belirsiz koşullar altında talep tahmini	Belirsiz koşullar altında talep tahmini ve kamçı etkisinin etkilerinin araştırıldığı çalışmada Ayrık Dalgacık Dönüşümleri ve YSA tabanlı bütünlük bir yaklaşım önerilmiş ve ARIMA modeli ile karşılaştırılmıştır. Önerilen modelin ARIMA modeline göre tahmin sonuçlarının daha iyi olduğu görülmüştür. Kamçı etkisinin talep tahmininin doğruluğundaki artış oranı ile beraber azaldığı gözlemlenmiştir.
2014	Babu ve Reddy	ARIMA ve YSA tabanlı melez bir model	Cilt lekesi, elektrik ve finansal veriler için tahmin	Önerilen melez model, karşılaştırılan diğer modeller arasında en yüksek tahmin doğruluğunu vermiştir.
2013	Du ve diğ.	DVM, Radyal Temel Fonksiyon	Bozulabilir ürünler sektörü	DVM modeli ile Radyal Temel Fonksiyon modeli BPR modeli karşılaştırılmış, DVM modelinin araştırma yapılan sektörde uygun sonuçlar verdiği görülmüştür.
2013	Guo ve diğ.	Uyum Arama temelli çok değişkenli bir karar verme modeli	Parekende sektörü	Çalışmada Uyum Arama temelli çok değişkenli bir karar verme modeli önerilmiş ve önerilen modelin performansı ekstrem öğrenme makinesi temelli bir model ve genelleştirilmiş doğrusal modelle karşılaştırılarak önerilen modelin üstünlüğü gösterilmiştir.
2012	Kandananond	DVM, YSA	Tüketici ürünleri için talep tahmini	Tüketici ürünleri talebini tahmin etmek amacıyla DVM ve YSA metodları kullanılmış, DVM metodunun daha iyi tahmini performansı gösterdiği görülmüştür.

Tablo 4.3: Literatür araştırması (devam)

2012	Lu ve diğ.	Çok Değişkenli Adaptif Regresyon Eğrileri, YSA	Bilgisayar toptancısı için satış tahmini çalışması	Çok Değişkenli Adaptif Regresyon Eğrilerinin daha iyi bir tahmin performansı sergilediği gösterilmiştir.
2011	Fildes ve Kingsman	Simülasyon	Tedarik zincirinde talep belirsizliği ve tahmin hatalarının müşteri ve fiyatlara etkisi	Talep belirsizliğin yüksek olduğu durumlara birim fiyatların arttığı, talep belirsizliğine tahmin sürecinin ayrı ayrı simüle edilmesi gerektiği sonucuna ulaşılmıştır.
2010	Chen-Ritzo ve diğ.	Stokastik programlama modelleri	Siparişe göre yapılandırma sistemlerinde talep ve arz dengesi	Çalışmada siparişlerin nasıl yapılandırıldığına ilişkin belirsizlik içeren durumlar iki aşamalı stokastik programlama yöntemleri ile analiz edilmiştir
2010	Ching-Chin ve diğ.	Yeni ürün tahmin sistemi	Yeni ürünler için satış tahmini	Tahmin modülünü Hareketli Ortalama, Üstel Düzeltme, Trend Düzeltmeli Üstel Düzeltme modelleri ve sezgisel yöntemlerden Satış Endeksi, Taylor Serisi ve Difüzyon Modellerini içeren yeni ürün tahmin sistemi önerilmiş ve önerilen sistemin yeni ürünler için tahmin konusunda iyi sonuçlar sergilediği sonucuna ulaşılmıştır.
2008	Sun ve diğ.	Ekstrem öğrenme makinası, Geri yayılım YSA	Moda sektörü	Ekstrem öğrenme makinası yönteminin özellikle talebin dalgalı olduğu durumlarda karşılaştırılan diğer modellerden daha uygun olduğu sonucuna ulaşılmıştır.
2006	Doganis ve diğ.	Radyal Temel Fonksiyon Sinir Ağı Mimarisi ve özel olarak tasarlanmış Genetik Algoritma metotlarının kombinasyonu olan yeni bir model	Süt ürünleri için satış tahmini	Önerilen modelin satış tahmini için uygun sonuçlar verdiği görülmüştür. İlerleyen çalışmalarda modelin geliştirilerek daha yüksek tahmin doğruluğu elde edilebileceği belirtilmiştir.

Tabrizi ve Ghaderi (2016), İnan'da st ve st rnleri reten bir iletmede ARIMA ve yerel dođrusal nro-bulanık modelleri kullanarak satı tahmini yapmılardır. nerilen dođrusal nro-bulanık modelin ARIMA yntemine gre daha iyi sonular verdiđi grlmtır. Bu yntem kullanılarak firma iin kısa dnemli tahminler yapılmıtır.

Raju ve diđ. (2015) kk ve orta lekteki toptancılar iin hava, tatil gibi faktrlerdeki deđikenliklerin talebi nasıl etkilediđini aratırmılardır. Temel bileenler analizi (Principle Component Analysis-PCA) yntemi ile deđikenlerin birbiri ile bađlılık derecesini lmeye alımılardır. Aratırma sonucunda kısa raf mrl rnlerin taleplerinin tahmin edilmesi iin dođrusal olmayan yntemlerin dođrusal yntemlerden daha dođru sonular verdiđi grlmtır.

Parimita ve Arora (2015) st rnleri iletmesinde farklı rn grupları iin satı tahmini alıması yrtmlardır. alımada saf model, hareketli ortalama modeli, stel dzletirme ve nedensel tahmin yntemleri (dođrusal regresyon ve stel regresyon) uygulanmıtır. Tahmin yntemlerinin performansının rn gruplarına gre deđikenlik gsterdiđi grlmtır.

Veiga ve diđ. (2014) bozulabilir st rnleri iletmesi iin 9 yıllık bir veri seti kullanarak ARIMA ve Holt-Winters yntemleri ile talep tahmini yapmılardır. Yazarlara gre ARIMA modelinde parametrelerin tahminindeki belirsizlik gsterilememektedir. Holt-Winters metodu basittir ve daha karmaık yntemler gibi dođru sonu verebilir. Fakat byk ufka sahip tahminler iin daha dk dođruluk eđilimindedir.

Murphy ve diđ. (2014) bir iđ st retim iftliđinde st retim veriminin tahminini yapmılardır. 3 yıllık bir veri setine Dı Girili Dođrusal Olmayan Oto-Regresif model, Statik Yapay Sinir Ađları ve oklu Dođrusal Regresyon yntemlerini uygulamılardır. Dı Girili Dođrusal Olmayan Oto-Regresif modelin en iyi sonucu verdiđi gzlenmitir.

Jaipuria ve Mahapatra (2014) belirsiz ortamda dođru talep tahmini yapmak ve aynı zamanda talepteki deđikenliđin sebep olduđu kamı etkisini azaltmak amacıyla  farklı sektrden (otomotiv, imento ve elik) almı olduđu veriler ile

talep tahmini yapmışlardır. Tahmin için Ayrık Dalgacık Dönüşümleri ve YSA tabanlı bütünlük bir yaklaşım önermişler ve önerdikleri modeli ARIMA yöntemi ile karşılaştırmışlardır. Önerilen modelin daha düşük tahmin hatası ile daha doğru sonuçlar verdiği gözlenmiştir ve önerilen modelin veri tipi ve niteliği fark etmeksizin tüm sektörlerdeki firmalar tarafından kullanılabilceği belirtilmiştir. Ayrıca, çalışmada doğru tahmin sonuçlarının kamçı etkisini, dolayısıyla da maliyetlerdeki artışları düşürdüğü görülmüştür.

Babu ve Reddy (2014) ARIMA ve YSA modellerini birleştirerek her iki modelin avantajlarından faydalanan melez bir tahmin yöntemi önermişlerdir. Önerdikleri modeli güneş lekesi verileri, elektrik fiyat verileri ve finansal veriler olmak üzere üç farklı veri setine uygulamışlardır. ARIMA, YSA ve yazarlar tarafından önerilen ARIMA-YSA melez modeli ile diğer bazı mevcut ARIMA-YSA melez modeller karşılaştırılmış, önerilen melez modelin en doğru tahmin sonuçlarını verdiği gözlemlenmiştir.

Du ve diğ. (2013) DVM metodunu kullanarak bozulabilir çiftlik ürünlerinin tahmini için bir uygulama yapmışlardır. DVM modeli ile Radyal Temel Fonksiyon metodu karşılaştırılmış, veri seti olarak üç farklı marketten alınmış elma ve muz satışından alınan veriler seçilmiştir. DVM metodunun bozulabilir çiftlik ürünleri üzerinde olumlu sonuçlar verdiği gözlenmiştir.

Guo ve diğ. (2013) perakende sektöründe satış tahmini yapmak için Uyum Arama temelli çok değişkenli bir karar verme modeli önermişlerdir. Önerilen modelin performansı ekstrem öğrenme makinesi temelli bir model ve genelleştirilmiş doğrusal modelle karşılaştırılmış ve önerilen modelin üstünlüğü gösterilmiştir.

Kandananond (2012) tüketici ürünleri talebini tahmin etmek için DVM ile YSA yöntemlerini karşılaştırmıştır. 6 farklı tüketici ürünüde (pişirme yardımcıları, duş jeli, vücut losyonu, bulaşık deterjanı, deodorant, kumaş deterjanı) 32 aylık geçmiş veriler kullanılmıştır. Bütün ürünler için en iyi sonucu veren metodun DVM olduğu görülmüştür.

Lu ve diğ. (2012) bir bilgisayar toptancısı için satış tahmini yaptıkları çalışmada, Çok Değişkenli Adaptif Regresyon Eğrileri ve YSA'nın performanslarını

karşılaştırmışlar ve kıyaslama sonucunda Çok Değişkenli Adaptif Regresyon Eğrilerinin daha iyi bir performans sergilediğini göstermişlerdir.

Chen ve Ou (2011) perakende sektöründe gri ilişkisel analiz ve Taguchi yöntemiyle ekstrem öğrenme makinesi yöntemlerini bütünleştirerek satış tahmini çalışması yapmışlardır. Gri aşırı öğrenme makinesi adı verilen bu metod gri geri yayılım ağı ve gri çok katmanlı fonksiyon bağlantı ağı ile karşılaştırılmıştır. Çalışmada iki farklı verinin sonucunu bulmak için Matlab® ve Minitab® paket programları kullanılmıştır. Gri aşırı öğrenme makinesi modelinin tahmin doğruluğunun diğer modellerden daha üstün olduğunu yaptıkları çalışmada gözlemlemişlerdir.

Fildes ve Kingsman (2011) talep belirsizliği ve tahmin hatalarının tedarik zincirinde birim maliyetler ve müşteri hizmet seviyelerindeki etkisini araştırmışlardır. Bir üretici için öngörülen tahmin doğruluğu değerini iyileştirmek için bir simülasyon modeli önermişlerdir. Çalışmada ayrıca, talep belirsizliğine ek olarak farklı boyutlardaki tahmin hatalarının yanlış tanımlanmasının etkileri de tahmin edilmiştir.

Chen-Ritzo ve diğ. (2010), siparişe göre yapılandırma sistemlerinde talep ve arz dengesi sorununu ele almışlardır. Çalışmada siparişlerin nasıl yapılandırıldığına ilişkin belirsizlik içeren durumlar iki aşamalı stokastik programlama yöntemleri ile analiz edilmiştir.

Ching-Chin ve diğ. (2010) yeni ürünler için bir satış tahmin modeli oluşturmuşlardır. Yeni ürün tahmin sistemi adını verdikleri bu model 4 aşamalı bir tahmin yürütmektedir. Tahmin yöntemi olarak klasik zaman serisi modellerinden Hareketli Ortalama, Üstel Düzeltme, Trend Düzeltmeli Üstel Düzeltme modelleri; sezgisel yöntemlerden de Satış Endeksi, Taylor Serisi ve Difüzyon Modeli tahmin modülünün içinde çalışacak yöntemler olarak belirlenmiştir. 27 farklı senaryo test edilerek önerilen sistemin üstünlüğü gösterilmiştir.

Sun ve diğ. (2008) satış miktarıyla talebi etkileyen faktörler arasındaki ilişkiyi araştırmak için ekstrem öğrenme makinesi yöntemini uygulamışlardır. Yazarlar satış miktarlarındaki dalgalanmanın tahmin doğruluğu üzerindeki etkisi

incelemişlerdir. Bir yaklaşımın tahmin doğruluğu genellikle bir ürünün doğası ve satış modelinden etkilenir. Çalışmada talep dalgalanmasının daha büyük olduğu ürünlerde ekstrem öğrenme makinesi yönteminin tahmin hatasının geri yayılma sinir ağlarına dayanan diğer yöntemlere kıyasla daha düşük olduğu görülmüştür.

Doganis ve diğ. (2006) kısa süreli raf ömrüne sahip ve insan sağlığını önemli ölçüde etkileyen süt ürünlerinin satış tahmini için Radyal Temel Fonksiyon Sinir Ağı Mimarisi ve özel olarak tasarlanmış Genetik Algoritma metotlarının kombinasyonu olan bir model önermişlerdir. Önerilen modelin başarılı bir tahmin performansı sergilediği görülmüş, sadece geçmiş satış verileri kullanıldığı için ilerleyen çalışmalarda fiyat, promosyon gibi bilgiler de eklenerek modelin performansının geliştirilebileceği belirtilmiştir.

5. YAPAY SINİR AĞLARI VE DESTEK VEKTÖR REGRESYONU

5.1 Yapay Sinir Ağları


Yapay Sinir Ağları ilk olarak 1943 yılında sinir hekimi Warren McCulloch ve matematikçi Walter Pitts tarafından yayınlanan “*Sinir Aktivitesinde Düşüncelere Ait Bir Mantıksal Hesap*” adlı makale ile ortaya atılmıştır. Yapay sinir ağları insan sinir sistemi yapısının bilgisayar üzerinde taklit edilmesidir. Diğer bir deyişle bilgisayarda oluşturulan yapay bir sinir ağı ile verilerin eğitilmesi ve öğrenme sürecidir (McCulloch ve Pitts 1943).

5.1.1 Yapay Sinir Ağlarının Yapısı ve Elemanları

YSA, insan beyninin çalışmasının bilgisayar sistemlerine aktarılması temeline dayanır. Genel olarak YSA işleyişi insan beyninin işleyişine benzer. Bu sebeple, bu bölümde önce insan beyninin yapısı ve hücreleri tanıtılıp ardından yapay sinir ağlarının nasıl oluşturulduğuna değinilecektir.

5.1.1.1 Biyolojik Sinir Hücresi

Biyolojik sinir hücresi yapısal olarak hücre gövdesi, dendrit ve aksondan oluşmaktadır. Dendrit, sinyalleri hücre gövdesine taşıyan yapıdır. Sinyaller hücre gövdesinde toplanır. Akson, sinyallerin diğer nöronlara aktarılmasını sağlayan yapıdır. Sinapslar ise bir hücrenin aksonu ile diğer hücrenin dendriti arasındaki bağlantıyı sağlar. Şekil 5.1’de biyolojik sinir hücre yapısı ve bir yapay sinir ağı görülmektedir.



Şekil 5.1: Biyolojik sinir hücresi yapısı ve yapay sinir ağı yapısı (Maltarollo ve diğ. 2013)

Şekil 5.1’de A, biyolojik hücre yapısını C ise hücreler arasındaki veri aktarımın sinapslar yolu ile iletimini göstermektedir. B ve D’de ise bu biyolojik hücre yapılarının yapay sinir ağlarındaki karşılıkları gösterilmiştir. B’de bir yapay sinir hücresi, D’de ise veri iletiminin yapay sinir ağlarında nasıl gerçekleştiği şekilsel olarak ifade edilmiştir. Tablo 5.1’de de biyolojik sinir sistemi yapısındaki her bir eleman karşı gelen yapay sinir ağı elemanları gösterilmektedir.

Tablo 5.1: Biyolojik sinir sistemi elemanları ve ona karşı gelen yapay sinir ağı elemanları

Biyolojik Sinir Sistemi	Yapay Sinir Ağı
Nöron	Yapay Sinir Hücresi
Sinaps	Ağırlıklar
Dendrit	Toplama Fonksiyonu
Hücre Gövdesi	Aktivasyon Fonksiyonu
Akson	Çıkış

Yapay sinir ağı, biyolojik sinir hücresinde nörona karşılık gelmektedir. Biyolojik sinir hücresinde veriler sinapslar ile iletilirken, yapay sinir hücresinde veriler ağırlıklar ile çarpılarak iletilmektedir. Dendrit görevini yapay sinir hücresinde toplama fonksiyonu, hücre gövdesi görevini ise aktivasyon fonksiyonu üstlenmektedir. Biyolojik sinir hücresinde aksonlar yoluyla üretilen bilgiler, yapay sinir hücresinde çıkış olarak nitelendirilmiştir.

5.1.1.2 Yapay Sinir Hücresi

Bir yapay sinir hücresi, girdiler, ağırlıklar, toplama fonksiyonu, aktivasyon fonksiyonu ve çıktılar olmak üzere beş yapıdan oluşmaktadır.

5.1.1.2.1 Girdiler

Yapay sinir hücresine gelen bilgilerdir. Bu bilgiler dış dünyadan veya diğer nöronlardan gelmektedir. Bilgiler fonksiyonlar aracılığıyla işlendikten sonra bir sonraki aşamaya iletilirler.

5.1.1.2.2 Ağırlıklar

Hücreye gelen veriler bağlantılar üzerindeki ağırlıklar ile çarpılarak çekirdeğe iletilirler. Her bir girişin bir ağırlığı bulunur. Bu ağırlık değerinin büyük ya da küçük olması girişin sinire güçlü ya da zayıf bağlanmasını etkiler. YSA'nın öğrenme işlevi bu ağırlıkların değiştirilmesi ile sağlanır.

5.1.1.2.3 Toplama Fonksiyonu

Hücreye gelen verileri ağırlıklar ile çarpıp toplayarak net girdiyi hesaplar. En çok kullanılan toplama fonksiyonu ağırlıklı toplam fonksiyonudur. Bunların dışında minimum, maksimum, çarpım, çoğunluk, kümülatif çarpım fonksiyonları da bulunmaktadır (Haykin 2009).

5.1.1.2.4 Aktivasyon Fonksiyonu

Hücreye gelen bilgiyi işleyerek üretilecek çıktıyı belirler. Çıktı aralığının sınırlandırılması için kullanılmaktadır (Haykin 2009). Eşik değer, transfer veya sıkıştırma fonksiyonu olarak da bilinmektedir. Tablo 5.2'de YSA'da kullanılan bazı aktivasyon fonksiyonları verilmiştir (Öztemel 2012).

5.1.1.2.5 Çıktılar

Aktivasyon hücresinde işlenen verilerin çıktı değeridir. Girdi değeri birden fazla olsa da tek bir çıktı değeri verir (Öztemel 2012).

Tablo 5.2: Aktivasyon fonksiyonu örnekleri

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

5.1.2 Yapay Sinir Ağlarının Özellikleri

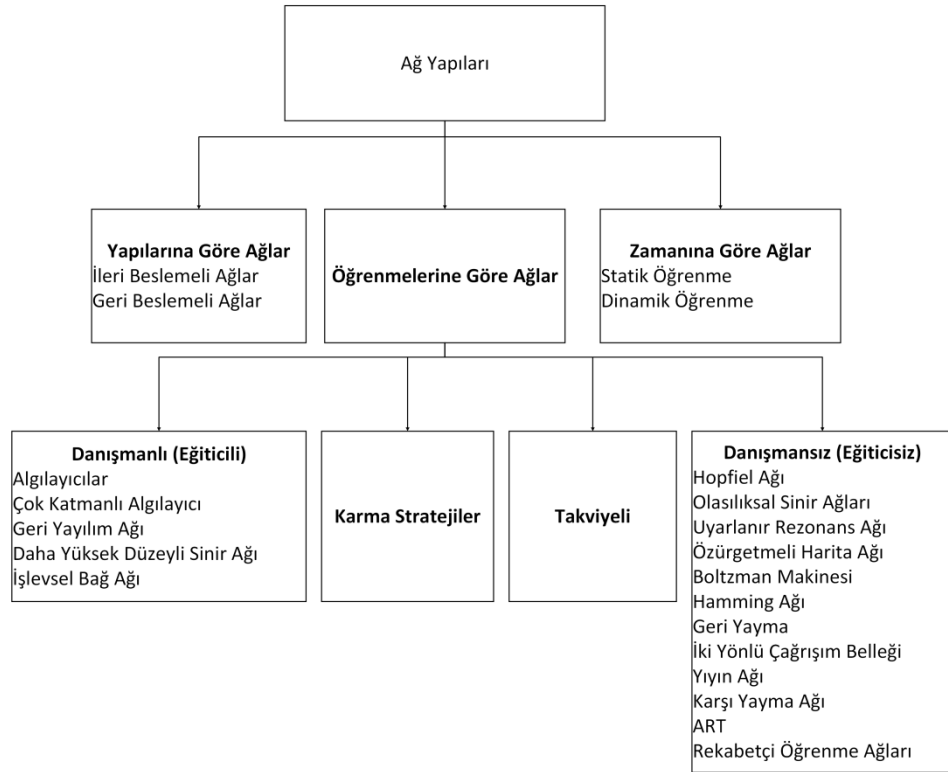
YSA'nın genel özellikleri aşağıdaki gibidir (Öztemel 2012):

- Makine öğrenimi ile çalışırlar.
- YSA'da bilgiler ağı içinde saklanır, meydana çıkarılması ve yorumlanması kolay değildir.
- YSA'ya örnek veri verilerek eğitilir.
- Doğru çalışmasının kontrol edilmesi için test edilir.
- Eğitim sayesinde görmediği veriler ile ilgili çıkarımlar yapabilir.
- Algılama yapabilirler.
- Şekil bağlantısı ve sınıflandırma yapabilirler.

- Eksik verilen örüntüler tamamlayabilirler.
- Kendine gösterilen örneklerle ile öğrenme yeteneğine sahiptirler.
- Hata toleransları vardır.
- Belirsizlik altında kendine verilen bilgileri öğrenerek, durumları ilişkilendirerek çalışabilirler.
- Hatanın derecesine göre gerçekleşen dereceli bozulma vardır.
- Ağın bütün bağlantıları birlikte çalışır. Bilgiler bütünsel dağıtılmıştır.
- Sayısal veriler ile çalışabilirler. Karakterlerin sayısal verilere dönüştürülmesi gerekir.

5.1.3 Yapay Sinir Ağlarının Sınıflandırılması

YSA çalışma mantığı açısından birbirlerine benzer fakat bazı yapısal farklılıklar göstermektedir. YSA'nın genel sınıflandırması aşağıdaki Şekil 5.2'de gösterilmektedir (Öztemel 2012).




Şekil 5.2: Yapay Sinir Ağlarının sınıflandırılması (Öztemel 2012)

5.1.3.1 Bağlantı Yapılarına Göre Ağlar

YSA sinir ya da düğüm adı verilen elemanlardan oluşur. Verilerin düğüm yerlerinden akış yönüne göre ağlar ikiye ayrılmaktadır. Bu ağlar İleri Beslemeli Ağlar ve Geri Beslemeli Ağlardır.

5.1.3.1.1 İleri Beslemeli Ağlar


Çok katmanlı sinir ağları olarak da tanımlanan bu modelde hücreler katmanlar halinde bulunur. Bir katmanın giriş verileri işlendikten sonra diğer katmana çıkış verileri olarak aktarılırlar. Dış katmandaki veriler bir işlem yapılmadan gizli katmana, orada işlendikten sonra da çıktı katmanına aktarılır. Bu modelin en önemli özelliği verilerin ileri doğru akması, geriye doğru bir veri aktarımı olmamasıdır. Yapısı Şekil 5.3'te gösterilmiştir.



Şekil 5.3: İleri beslemeli Yapay Sinir Ağları (Uslu 2016)

5.1.3.1.2 Geri Beslemeli Ağlar

Geri beslemeli ağ modelinde sadece ileriye doğru veri akışı olmaz, geriye doğru da bir veri akışı söz konusudur. Veriler çıkıştan girişe veya gizli katmandan girişe doğru iletilirler. Doğrusal olmayan dinamik bir yapıdır. Geriye doğru besleme yapmasından dolayı hataları azaltmaya yönelik çalışır. Bu nedenle zaman serileri ve tahmin problemlerinde makul sonuçlar vermektedir. (Yanık 2019). Yapısı Şekil 5.4'te gösterilmiştir.



Şekil 5.1: Geri beslemeli Yapay Sinir Ağları (Uslu 2016)

5.1.3.2 Öğrenmelerine Göre Ağlar

Öğrenme yapılarına göre ağlar aşağıdaki gibi sınıflandırılmaktadır.

5.1.3.2.1 Danışmanlı Ağlar

Bu ağ yapısında ağın eğitimi için bir danışman bulunmaktadır. Bu danışman ağa örnek girdi ve çıktı seti gönderir. Ağ bu girdileri öğrenerek çıktı oluşturur. Gerçek çıktı ile ağın ürettiği çıktı karşılaştırılarak hata oranları belirlenir. Hatayı minimize etmek amacı ile ağırlıklar yeniden verilir ve bu işlem optimum sonuca ulaşincaya kadar devam eder. Çok katmanlı algılayıcılar danışmanlı ağların en çok bilinen örneğidir (Öztemel 2012).

5.1.3.2.2 Karma Stratejiler

Birden fazla ağ yapısının birlikte kullanıldığı yapılardır. Danışmanlı ve danışmansız öğrenme yapmaktadır. Olasılık tabanlı ağlar ve radyal tabanlı ağlar bu yapılara örnektir (Sarı 2016).

5.1.3.2.3 Takviyeli Ağlar

Bu ağ yapısında bir danışman bulunmaktadır fakat bu danışman ağa veri vermez, ağın ürettiği çıktının doğru ya da yanlış olduğu ile ilgili ağa sinyal gönderir. Ağ bu sinyale göre öğrenerek kendi çıktısını düzenlemeye devam eder. Doğrusal Vektör Parçalama modeli bu ağlara örnek verilebilir (Öztemel 2012).

5.1.3.2.4 Danışmansız Ağlar

Danışmansız ağ yapısında bir danışman bulunmamaktadır. Ağa verilen bilgiler sadece giriş verileridir. Çıktının ağ tarafından öğrenmeden oluşturulması beklenir. Sadece çıktıların anlamlarının kullanıcı tarafından etiketlenmesi gerekmektedir. Adaptif Rezonans Teori ağları bu ağlara örnektir (Öztemel 2012).

5.1.3.3 Zamanına Göre Ağlar


Ağın eğitim sürecindeki parametrelerin zaman içinde değişip değişmediğine göre ikiye ayrılırlar: Statik öğrenme ve dinamik öğrenme. Eğer YSA eğitim sürecinde ağ üzerindeki katsayılar bir değişme olmuyorsa, katsayılar eğitim süreci boyunca sabitse bu ağlarda statik öğrenme söz konusudur. Eğer ağ yapısındaki katsayılar eğitim sürecindeki öngörülere göre değişiyorsa yani eğitim süreci boyunca katsayılar ağın öğrenme düzeyine göre değişim gösteriyorsa bu ağlarda dinamik öğrenme söz konusudur.

5.1.4 Yapay Sinir Ağı Modelleri

Yapay sinir ağlarının sınıflandırılmasından sonra bu kısımda farklı tipteki ağ modelleri ve çalışma şekilleri anlatılmıştır.

5.1.4.1 Tek Katmanlı Algılayıcılar

Tek katmanlı yapay sinir ağında bir girdi ve bir çıktı katmanı bulunur (Şekil 5.5). Her hücrede birden fazla girdi veya çıktı bulunabilir. Bütün çıktılar bütün girdilere bağlanır. Bütün bağlantıların bir ağırlığı vardır. Bu modelde çıktının sıfır olmasını engelleyen bir eşik değeri bulunur ve bu değer her zaman 1'dir. Çıktı bu eşik değeri ile ağırlıklandırılmış girdiler toplanarak elde edilir.



Şekil 5.2: Tek katmanlı algılayıcının yapısı

Tek katmanlı algılayıcıların en önemlileri Basit Algılayıcı (Perceptron) ve Adaline/Madaline'dir.

5.1.4.1.1 Basit Algılayıcı

İlk kez 1958 yılında Rosenblat tarafından örüntü sınıflandırma amacıyla ortaya atılmıştır. Birden çok girdi kullanılarak bir çıktı oluşturma mantığı ile çalışır. Çıktı 1 veya 0'dır. Çıktı değeri eşik değeri ile hesaplanır. Eşik değeri eğitilebilen, yani ağırlıkları değiştirilebilen yalnızca bir hücreden ibarettir. Girdiler ve çıktılar proses elemanına tanıtılır ve öğrenme kuralına göre çıktı hesaplaması yapılır. Beklenen ve hesaplanan farklı ise ağırlıklar ve eşik değeri değiştirilir. Değişiklik, öğrenme kuralına göre belirlenir. (Öztemel 2012).

5.1.4.1.2 Adaline

1959 yılında Bernard Widrow ve Marcian Hoff tarafından geliştirilmiş olan modelin adı adaptif doğrusal elemanın kısaltılmışıdır. En küçük ortalama kare metoduna dayanmaktadır. Öğrenme kuralına delta kuralı da denir. Öğrenme kuralı, ağırlık çıktısı ile beklenen çıktı arasındaki farkı minimize etmek için ağırlıkların değiştirilmesi sistemine dayanır. Yapı olarak basit algılayıcıya benzemektedir fakat basit algılayıcı eşik fonksiyonunu, Adaline ise doğrusal fonksiyon kullanır.(Öztemel 2012).

5.1.4.1.3 Madaline

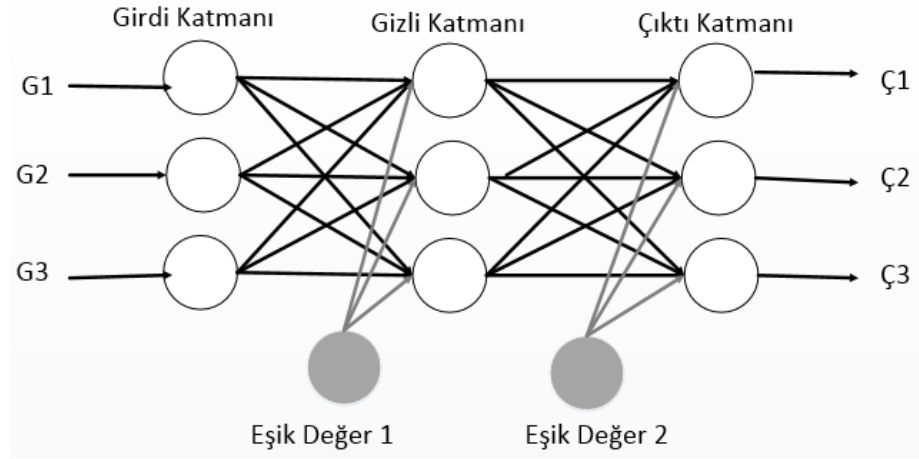
Madaline ağırları birden çok Adaline ağından oluşmaktadır. Madaline genellikle iki katmanlıdır. Bu katmanlarda farklı sayılarda Adaline ağırları bulunur.

Ağın çıktısı 1 veya -1'dir. Her bir çıktı değeri bir sınıfı temsil eder. Madaline öğrenme kuralı da en küçük kareler metoduna dayanır (Öztemel 2012).

5.1.4.2 Çok Katmanlı Algılayıcılar

Tek katmanlı algılayıcılar doğrusal olayları çözebilme kabiliyetine sahiptir. Fakat girdi ve çıktı arasında doğrusal olmayan bağlantı olduğunda tek katmanlı algılayıcılar yetersiz kalmaktadır. Bu durumda daha gelişmiş bir model olan Çok Katmanlı Algılayıcılar (ÇKA) devreye girmektedir.

Bir YSA'nın öğrenmesi istenilen problemin girdi ve çıktıları arasında doğrusal olmayan bir ilişki olduğunda daha önce bahsedilen modelleri ile çözülmesi mümkün değildir. Bu problemleri çözmek için daha gelişmiş modeller gereklidir. Problemin doğrusal olup olmadığının anlaşılması konusunun daha netleşmesi için XOR problemine bakmak gerekir. Bu problemdeki XOR fonksiyonu doğrusal olarak ayrılabilen bir fonksiyon değildir. Tek katmanlı algılayıcıların doğrusal olmayan problemleri çözemediği izlenimi ilk olarak bu problem ile oluşmuştur. Tek katmanlı algılayıcıların doğrusal problemleri çözmemesi üzerine YSA'nın başarısız olduğu izlenimi doğmuş, birkaç araştırmacı dışında YSA ile ilgili çalışmalar durdurulmuştur. XOR probleminin çözümü için yapılan çalışmalar sonucu David Rumelhart ve arkadaşları tarafından bu model geliştirilmiş ve YSA tekrar gündeme gelmiştir. ÇKA Delta öğrenme kuralı adı verilen öğrenme kuralını kullanır. Temel amacı ağın çıktısı ile hedeflenen değer arasındaki farkı minimize ederken bunu yayararak yapmak olduğu için Hata Yayma Ağı veya Geriye Yayım Modeli de denmektedir (Öztemel 2012). Yapısı Şekil 5.6'da verilmiştir.



Şekil 5.3: Çok katmanlı algılayıcının yapısı (Öztemel 2012).

- *Girdi Katmanı:* Dışarıdan gelen veri (G_1, G_2, \dots, G_n) ana katmana gönderilir. Katmana birden çok veri gelebilir fakat her proses elemanına yalnızca bir adet girdi gelir ve bir adet çıktı oluşur. Her bir çıktı bir sonraki katmanda bulunan bütün proses elemanlarına iletilir. Yani her bir proses elemanı kendinden sonraki katmanda bulunan tüm proses elemanlarına bağlıdır.
- *Ara (Gizli) Katman:* Girdi katmanından gelen verilerin aktarılıp işlendiği katmandır. Bir ÇKA'da birden fazla gizli katman ve bir gizli katmanda da birden fazla proses elemanı olabilir.
- *Çıktı Katmanı:* Ara katmandan gelen işlenmiş verileri, giriş katmanına göre çıktıya dönüştürüp dışarı veren katmandır. Birden fazla proses elemanı olabilir fakat her bir proses elemanının yalnızca bir adet çıktısı olabilir (Öztemel 2012).

ÇKA Genelleştirilmiş Delta Öğrenme Kuralını kullanır. Genelleştirilmiş Delta Öğrenme Kuralı iki safhadan oluşur:

1. İleriye Doğru Hesaplama
2. Geriye Doğru Hesaplama

5.1.4.2.1 İleriye Doğru Hesaplama

Bu safhada ağın çıktıları hesaplanır.

1.Adım: Veriler girdi katmanından ağa gönderilir. Fakat bu katmanda herhangi bir işlem yapılmadan ara katmana iletilir. Girdi katmanındaki k . proses elemanının çıktısı Denklem (5.1) ile hesaplanır.

$$\zeta_k^i = G_k \quad (5.1)$$

G_k : k . girdi katmanına gelen bilgiler (G_1, G_2, \dots, G_n)

2.Adım: Girdi katmanından gelen veriler ağırlıklar ile çarpılarak ara katmana gelir. Bu değerler toplanarak net girdi bulunur. Bu işlem Denklem (5.2)'de gösterilmiştir.

$$Net_j^a = \sum_{k=1}^n A_{kj} \zeta_k^i \quad (5.2)$$

A_{kj} : k . girdi elemanı katmanını j . ara katman elemanına bağlayan bağlantının ağırlık değeri

Çıktıların hesaplanması için net girdi aktivasyon fonksiyonundan geçirilir. Burada farklı fonksiyonlar kullanılabilir. Denklem (5.3)'te sigmoid aktivasyon fonksiyonunun çıktısı verilmiştir. Önemli olan nokta burada kullanılan fonksiyonun türevinin alınabilir olmasıdır, çünkü geriye doğru hesaplamada bu fonksiyonun türevi alınacaktır.

$$\zeta_j^a = \frac{1}{1 + e^{-(NET_j^a + B_j^a)}} \quad (5.3)$$

B_j : ara katmanda bulunan j . elemana bağlanan eşik değer elemanının ağırlığı

Eşik değeri çıktısı sabittir ve 1'e eşittir. Ağırlık değeri sigmoid fonksiyonunun oryantasyonunu belirlemek için dikkate alınır. Bu değeri ağın kendisi belirler.

3.Adım: Ara katmanda verilerin hesaplanmasıyla bütün proses elemanlarının ve çıktıların değerleri hesaplanmış olur. Çıktı değerlerinin çıktı katmanına gönderilip dışarıya verilmesi ile ilk safha tamamlanır (Öztemel 2012).

5.1.4.2.2 Geriye Doğru Hesaplama

Ağın çıktıları ve beklenen çıktıları arasındaki hatanın en küçük olması amacıyla geriye doğru hesaplama yapılırken bu hatalar ağırlık değerlerine dağıtılır. Çıktı katmanındaki m . süreç elemanı için hata değeri Denklem (5.4)'deki gibi hesaplanır. Bu denklemde B_m beklenen çıktıyı ifade etmektedir.

$$E_m = B_m - \zeta_m \quad (5.4)$$

Toplam hata ise Denklem (5.5) ile hesaplanır:

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

Toplam hatanın en küçük olması için süreç elemanlarına dağıtılması yani ağırlıkların değiştirilmesi gerekir. Bunun için iki farklı yaklaşım vardır:

- Ara katman ve çıktı katmanı arasındaki ağırlıkların değiştirilmesi
- Ara katmanlar arası veya ara katman ile çıktı katmanı arasındaki ağırlıkların değiştirilmesi.

Ara katman ve çıktı katmanı arasındaki ağırlıkların değiştirilmesi

Denklem (5.6)'da j . süreçteki elemanı çıktı katmanındaki m . süreç elemanına bağlayan bağlantı ağırlığının değişimi verilmektedir.

$$\Delta A_{jm}^a(t) = \lambda \delta_m \zeta_j^a + \alpha \Delta A_{jm}^a(t-1) \quad (5.6)$$

Burada;

t : iterasyon sayısı

λ : öğrenme katsayısı (ağırlıkların değişim miktarı)

α : momentum sayısı (ÇKA'nın eğitimi sırasında lokal optimuma odaklanmaması için ağırlık değişiminin belli oranının bir sonraki değişime ilave edilmesine yardımcı olan parametre)

δ : m . çıktı biriminin hatasını ifade etmektedir.

$$\delta_m = f'(NET)E_m \quad (5.7)$$

$f'(NET)$: Aktivasyon fonksiyonun türevi

Sigmoid aktivasyon fonksiyonu kullanılırsa bu değer:

$$\delta_m = \zeta_m(1 - \zeta_m) \cdot E_m \quad (5.8)$$

Değişim bulunduktan sonra t . iterasyondaki yeni ağırlık değeri Denklem (5.9) ile hesaplanır:

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

Ayrıca eşik değer biriminin de ağırlıkları değiştirilmelidir. İlk olarak değişim miktarı Denklem (5.10) ile bulunur. Bu denklemde β^c çıktı katmanındaki süreç elemanının eşik değer ağırlıklarını göstermektedir.

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

Eşik değer t . iterasyondaki yeni ağırlık değeri ise Denklem (5.11) ile hesaplanır.

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

Ara katmanlar arası veya ara katman ile girdi katmanı arasındaki ağırlıkların değiştirilmesi

Ara katmana gelen veriler girdi katmanı veya bir önceki ara katmandan geldiği için girdi katmanı ve ara katman arasındaki ağırlıkların sebep olduğu çıktı katmanındaki süreç elemanlarının hatasına bakılır. Bu sebeple girdi katmanı ve ara katman arasındaki ağırlıklar değiştirilirken çıktı katmanındaki bütün süreç elemanlarının hatasının payı alınır.

Bu ağırlıklardaki değişim miktarı Denklem (5.12)'deki gibi hesaplanır.

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

Hata terimi δ ise Denklem (5.13) ile hesaplanır.

$$\delta_j^a = f'(NET) \sum_m \delta_m A_{jm}^a \quad (5.13)$$

Sigmoid aktivasyon fonksiyonu kullanılırsa bu hata değeri:

$$\delta_j^a = \zeta_j^a (1 - \zeta_j^a) \sum_m \delta_m A_{jm}^a \quad (5.14)$$

Aynı şekilde eşik değeri biriminin yeni ağırlıkları da Denklem (5.15) ile hesaplanmaktadır.

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

Değişim miktarı ise Denklem (5.16) ile hesaplanır. Bu denklemde β^a Ara katman eşik değeri ağırlıklarını göstermektedir.

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

Son olarak t . iterasyonda ağırlıkların yeni değeri Denklem (5.17) ile bulunur.

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

Bütün ağırlıklar bu şekilde değiştirilerek ileri ve geri hesaplamalar tamamlanır. Aynı işlemler eğitim tamamlanıncaya kadar her iterasyonda tekrarlanır (Öztemel 2012).

5.2 Destek Vektör Algoritmaları

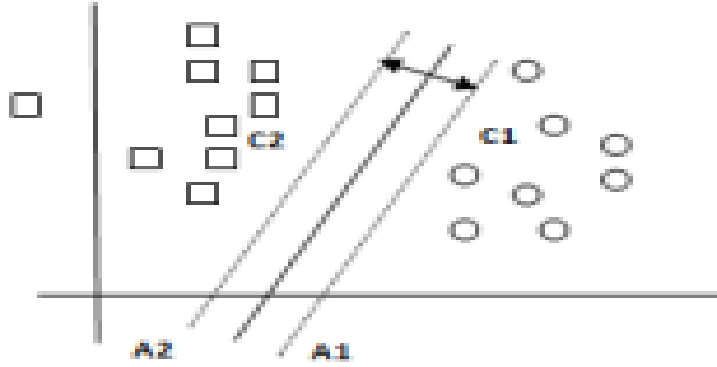
Destek vektör algoritmaları iki farklı mekanizma ile çalışır. Bunlardan biri sınıflandırma temelli olan Destek Vektör Makineleri, diğeri ise regresyon temelli olan Destek Vektör Regresyonudur. Destek Vektör Makineleri ilk olarak Vladimir Vapnik tarafından ortaya atılmıştır. Temeli istatistiksel öğrenme teorisine dayanmaktadır ve ilk olarak sınıflandırma için kullanılmıştır (Vapnik 1995). Daha sonra tahmin için kullanılan Destek Vektör Regresyonu geliştirilmiştir (Drucker ve diğ. 1997).

5.2.1 Destek Vektör Makineleri

DVM önce ikili sınıflandırma için ortaya atılmasına rağmen daha sonra gerçek hayatta daha fazla sınıflandırma ihtiyacı olması nedeniyle çoklu sınıflandırma olarak geliştirilmiştir (Wang ve Xue 2014).

DVM’de iki tür durumla karşılaşılmaktadır.

Doğrusal ayrılabilme durumu: Bu durumda veriler incelendiğinde doğrudan bir düzlem ile birbirlerinden doğrudan ve kolayca ayrılabilir. DVM çalışma prensibi ile bu aşırı düzlemin iki tarafında kalan verilerin eşit uzaklıkta olmasını sağlamaktadır.



Şekil 5.4: Doğrusal ayrılabilme durumunda ayırıcı düzlem (Özkan 2008)

Hesaplamaya ait formüller aşağıdaki gibidir:

Ayırıcı aşırı düzlem Denklem (5.18) ile belirlenmektedir.

$$w \cdot x + b = 0 \quad (5.18)$$

Burada w ağırlık vektörünü, b ise sabit sayı (bias) değerini göstermektedir.

$$c_1 \text{ doğrusu} \quad : w \cdot x + b = -1 \quad (5.19)$$

$$c_2 \text{ doğrusu} \quad : w \cdot x + b = 1 \quad (5.20)$$

c_1 ve c_2 doğruları aşırı düzlemin eşit uzaklıklardaki görüntüsüdür. Ve bu doğrular arasındaki uzaklık (marjin) d ile gösterilirse;

$$d = \frac{2}{|w|} \quad (5.21)$$

$$|w| = \sqrt{w_1^2 + w_2^2} \quad (5.22)$$

d 'nin maksimum değeri bulunması için $|w|$ değerinin minimum bulunması gerekir.

Bu durum da aşağıdaki kuadratik optimizasyon probleminin çözülmesini gerektirir.

$$\text{Min } \frac{1}{2} |w|^2 \quad (5.23)$$

Kısıtlar

$$(w \cdot x) + b \geq 1 \text{ ise } y_i=1 \text{ (sınıf 1-kare)} \quad (5.24)$$

$$(w \cdot x) + b \leq -1 \text{ ise } y_i=-1 \text{ (sınıf 2-daire)} \quad (5.25)$$

Bu kısıtlar birleştirilirse

$$y_i \cdot ((w \cdot x) + b) \geq 1 \quad (5.26)$$

Buna göre kuadratik problem aşağıdaki şekli alır.

$$\text{Min } \frac{1}{2} |w|^2 \quad (5.27)$$

Kısıtlar

$$y_i \cdot ((w \cdot x) + b) \geq 1 \quad (5.28)$$

Aşırı düzlemin sınıfları ayıramadığı durumda, sınırı aşma durumunu simgeleyen ζ_i parametresi amaç fonksiyonuna dahil edilir ve bu parametrenin minimum olması sağlanır.

$$\text{Min } J(w; \zeta) = \frac{1}{2} |w|^2 + C \sum_{i=1}^n \zeta_i \quad (5.29)$$

Kısıtlar:


$$y_i \cdot ((w \cdot x) + b) \geq 1 - \zeta_i \quad i=1,2,\dots,n \quad (5.30)$$

$$\zeta_i \geq 0 \quad (5.31)$$

Bu denklemlerde ζ_i : gevşek değişkeni C ise Lagrange çarpanının alabileceği üst sınır değerini gösteren ceza parametresini ifade eder.

Bu problemlerde w, b ve ζ_i değişkenlerinin en iyi değerleri aranmaktadır. C değeri $(0, \infty)$ aralığında olabilir. C değeri 0'a yaklaştıkça ζ_i değeri kısıtsız duruma gelir ve en büyük marjin genişliği elde edilir. Tam tersi durumda yani C sonsuza yaklaştıkça duyarlılık artar, marjin genişliği azalır. C değeri kullanıcının seçimine bırakılır (Vapnik 1995).

Doğrusal Ayrılama Durumu: Verilerin doğrusal bir düzlem ile ayrılabilmesi durumudur. Bu durumda doğrusal sınıflandırıcı yerine doğrusal olmayan sınıflandırıcılar kullanılır.



Şekil 5.5: Doğrusal ayrılama durumunda doğrusal olmayan ayırıcı düzlem (Özkan 2008)

Kecman (2001) yaptığı çalışmasında farklı bir uzayda çekirdek fonksiyonları tabanlı bir çalışma ile ayrıştırılmayı eğitim veri seti üzerinde yine amaca uygun gerçekleştirilebileceğini göstermiştir. Ayrı fonksiyonlar oluşturmak yerine eğitim örneği üzerindeki fonksiyonları ile hesaplama kolaylığı yaratmıştır.

$x \rightarrow \phi(x)$ dönüşümü ile ayırıcı düzlem formül (5.32)'deki şekle dönüştürülür.

$$f(x) = w \cdot \phi(x) + b = 0 \quad (5.32)$$

İki boyutlu uzayda (x_i, x_j) çarpımı çok boyutlu uzayda $(\phi_i \cdot \phi_j)$ şeklindedir. $(\phi_i \cdot \phi_j)$ çarpımı yerine aşağıdaki gibi bir K fonksiyonu tanımlanabilirse çok büyük veri miktarları için çok büyük zaman harcanarak hesaplanabilen $(\phi(X_1) \cdot \phi(X_2))$ çarpımı yerine $K(X_1, X_2)$ çarpımı ile bu hesaplamalar çok daha az işlem zaman ile yapılabilecektir. K fonksiyonu aşağıdaki gibi tanımlanmaktadır (Vapnik 1995):

$$K(X_1, X_2) = (\phi(X_1) \cdot \phi(X_2)) = (\phi(X_1)^T \cdot \phi(X_2)) = (\phi(X_1), \phi(X_2)) \quad (5.33)$$

5.2.2 Destek Vektör Regresyonu

Destek Vektör Regresyonu, DVM'ye benzer fakat bazı farklılıklara sahiptir. Sınıflandırmada veri setlerini ayıran düzlem sınırları arasında veri kalmayacak şekilde maksimize edilir, fakat regresyonda bu düzlem sınırları arasında maksimum veri kalacak şekilde ayırma işlemi yapılır.


$$(x_1, y_1), (x_2, y_2), \dots, (x_i, y_i) \quad x \in R^d, y \in R$$

$$f(x) = w \cdot x_i + b \quad (5.34)$$

Burada x_i d boyutlu uzayın girdi vektörü, y_i çıktı vektörü ve w ağırlık vektörüdür.

5.2.2.1 Doğrusal Destek Vektör Regresyonu

Doğrusal DVR'de amaç x_i değerinden, y_i 'yi hesaplayabilecek bir $f(x)$ fonksiyonu bulmaktır. Burada tahmini y_i değeri hata toleransından (ϵ) büyük olmayan bir uzaklıktadır yani DVR'de ϵ 'dan daha küçük veya eşit hatalı veriler hatasız kabul edilir, fakat bu değerden büyük hatalar reddedilir.



Şekil 5.6: Doğrusal regresyon için ϵ değeri (Erdoğan 2019)


Denklem (5.34)'ün düz olması, w 'nin küçük olması demektir. Bunun için de $\|w\|^2$ minimum olmalıdır. Bunun için aşağıdaki optimizasyon problemi çözülür:

$$\min \frac{1}{2} \|w\|^2 \quad (5.35)$$

Kısıtlar

$$|y_i - (w \cdot x_i) + b| \leq \epsilon \quad (5.36)$$

Bu durum bütün veriler için geçerli değildir. Bunu ortadan kaldırarak bir $f(x)$ fonksiyonu elde edebilmek amacıyla bütün noktalar için esneklik fonksiyonu ξ^+ ve ξ^- kullanılır.



Şekil 5.10: Doğrusal regresyon için ϵ değeri ve esneklik değişkeni (Erdoğan 2019)

Denklem (5.36)'deki kısıtlara ξ değişkeni eklendiğinde kısıtlar Denklem (5.37)-(5.39) gibi olur. Bu denklemlerde C ceza katsayısını göstermektedir.

$$|y_i - (w \cdot x_i) + b| \leq \epsilon + \xi^+ \quad (5.37)$$

$$|y_i - (w \cdot x_i) + b| \leq \epsilon + \xi^- \quad (5.38)$$

$$f(x) = C \sum_{i=1}^L \xi_i^+ + \xi_i^- + \frac{1}{2} \|w\|^2 \quad (5.39)$$

Kısıtlara ait hata fonksiyonunu minimize etmek için Lagrange çarpanları (α ve μ) kullanıldığında (5.40) denklemini elde edilir:

$$L_p = C \sum_{i=1}^L \xi_i^+ + \xi_i^- + \frac{1}{2} \|w\|^2 - \sum_{i=1}^L \mu_i^+ \xi_i^+ + \mu_i^- \xi_i^- - \sum_{i=1}^L \alpha_i^+ (\epsilon + \xi_i^+ + y_i - f(x_i)) - \sum_{i=1}^L \alpha_i^- (\epsilon + \xi_i^- - y_i - f(x_i)) \quad (5.40)$$

Optimum çözümde w , b , ξ^+ ve ξ^- parametrelerine göre L_p 'nin kısmi türevleri 0'a eşitlenir.

$$\frac{\partial L_p}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^L (\alpha_i^+ - \alpha_i^-) x_i = 0 \quad (5.41)$$

$$\frac{\partial L_p}{\partial b} = 0 \Rightarrow w = \sum_{i=1}^L (\alpha_i^+ - \alpha_i^-) = 0 \quad (5.42)$$

$$\frac{\partial L_p}{\partial \xi_i^+} = 0 \Rightarrow C = \alpha_i^+ + \mu_i^+ = 0 \quad (5.43)$$

$$\frac{\partial L_p}{\partial \xi_i^-} = 0 \Rightarrow C = \alpha_i^- + \mu_i^- = 0 \quad (5.44)$$

Veri setinin aşağıdaki şartları yerine getirdiği varsayılır ve Denklem (5.41) ve (5.42), Denklem (5.40)'da yerine konur ve L_p , α_i^+ ve α_i^- 'ye enbüyüklenir:

$$0 \leq \alpha_i^+, \alpha_i^- \leq C \quad \sum_{i=1}^L (\alpha_i^+ - \alpha_i^-) = 0 \quad \forall_i$$

$$L_p = \sum_{i=1}^L (\alpha_i^+ - \alpha_i^-) f(x_i) - \epsilon \sum_{i=1}^L (\alpha_i^+ - \alpha_i^-) - \frac{1}{2} \sum_{i,j} (\alpha_i^+ - \alpha_i^-) (\alpha_j^+ - \alpha_j^-) x_i \cdot x_j \quad (5.45)$$

(5.41) denklemini (5.34)'de yerine konur ve (5.46)'daki tahmin fonksiyonu elde edilir:


$$f(x) = \sum_{i=1}^L (\alpha_i^+ - \alpha_i^-) x_i \cdot x + b \quad (5.46)$$

S destek vektörleri $0 \leq \alpha \leq C$ ve $\xi_i^+ = 0$ (veya $\xi_i^- = 0$) şartlarını yerine getiren i indisleri bulunarak oluşturulabilir.

$$b = f(x_s) - \epsilon - \sum_{m \in S} (\alpha_m^+ - \alpha_m^-) x_m \cdot x_s \quad (5.47)$$

5.2.2.2 Doğrusal Olmayan Destek Vektör Regresyonu

Doğrusal regresyon modelinin yeterli olmadığı durumlarda, doğrusal ayırım yapabilmek için veri özellik alanı yüksek boyutlu bir hale dönüştürülür. Doğrusal regresyonda optimum fonksiyon girdi uzayında aranırken doğrusal olmayan regresyonda özellik uzayında aranır. Çalışma yapısı olarak doğrusal regresyon ile aynıdır. Ancak doğrusal regresyonda özellik uzayında aranır (Huang ve diğ. 2006).



Şekil 5.11: Doğrusal olmayan regresyon için ϵ değeri (Erdoğan 2019)

Doğrusal olmayan regresyon, (5.45) denklemindeki $(x_i \cdot x_j)$ çarpımı ile $K(x_i \cdot x_j) = \phi(x_i) \cdot \phi(x_j)$ doğrusal olmayan kernel fonksiyonu yer değiştirir. Tahmin fonksiyonu Denklem (5.48)'deki gibi hesaplanır:

$$f(x) = \sum_{i=1}^L (\alpha_i^+ - \alpha_i^-) K(x_i \cdot x) + b \quad (5.48)$$

Literatürdeki uygulamalar incelendiğinde, YSA yöntemi, kullandığı matematiksel hesaplamalar ile en iyi sonucu verdiği izlenimi kazandırmaktadır. Ancak nöron sayısı artırımına dayalı yaklaşım ile bulduğu bu değer küresel en iyi olduğunu garanti edememektedir. Bu kesin yargıya ulaşabilmek ancak sonsuz nöron

sayısı ile çalışmakla olabilir fakat bu da mantıksal ve matematiksel anlamda mümkün olmadığı için YSA küresel en iyiyi garanti etmede geri planda kalan bir modeldir. Bunun aksine DVR doğrusal ya da en kompleks modeller için konveks bir yapıyla ayrıştırma fonksiyonu sayesinde küresel en iyiye daha kolay ulaşabilmekte daha doğru bir ifade ile küresel en iyiyi garanti edebilmektedir. Bu özelliği ile DVR algoritması yerel optimuma takılmadan küresel en iyiye ulaşma konusunda başta YSA olmak üzere diğer yöntemlere göre ön plana çıkabilmektedir.

6. UYGULAMA

Bu bölümde belirsizliğin yoğun olarak yaşandığı gıda sektöründeki bir işletmede yapay sinir ağları ve destek vektör regresyonu yöntemleri kullanılarak tahmin çalışması yürütülmüştür. Literatürden de bilindiği üzere belirsizliğin hâkim olduğu durumlarda geleneksel tahmin yöntemleri yetersiz kalmakta, bu gibi durumlarda yapay zekâ yöntemleri daha iyi sonuçlar vermektedir. Bu nedenle çalışmada bu iki yöntem tercih edilmiştir. Yöntemlerden başarılı sonuçlar elde edebilmek için ön çalışma olarak parametre optimizasyonu yapılmış, daha sonra en uygun parametre değerleri ile tahmin yapılmıştır. Uygulamanın aşamaları ilerleyen alt bölümlerde adım adım anlatılmıştır.

6.1 Veri Seti

Uygulama çabuk bozulabilir ürünlerin üretildiği bir gıda işletmesinin verileri kullanılarak gerçekleştirilmiştir. Firmadan 4 farklı ürüne ait 52 aylık satış miktarı, üretim miktarı, birim üretim maliyeti, depolama maliyeti, satış fiyatı, dönem başı stok miktarı, hazırlık maliyeti ve elde bulundurma maliyeti gibi veriler temin edilmiş ve bu veriler tahmin için kullanılmıştır. Bu dört ürün için MATLAB® 2018a paket programının YSA ve DVR araçları kullanılarak tahmin yapılmıştır.


Eldeki verilerle tahmin yapılmadan önce veriler istatistiksel olarak analiz edilmiştir. Tablo 6.1’de talep tahmini yapılacak 4 ürüne ait gerçekleşmiş satış miktarlarına (koli/ay) ait istatistikler görülmektedir.

Tablo 6.1: Ürünlerin geçmiş satış miktarlarına ait istatistik değerler

Ürün	<i>N</i>	Minimum Değer	Maksimum Değer	Standart Sapma
Ürün 1	52	94,920	126,258	8,527
Ürün 2	52	2,586	11,697	2,745
Ürün 3	52	1,430	7,451	1,594
Ürün 4	52	1,247	9,405	2,064


6.2 Verilerin Trend ve Mevsimsellik Analizi

Talep tahmini çalışması yapılacak 4 ürün için Ocak 2015–Nisan 2019 ayları arasında gerçekleşen satış miktarları incelenmiştir. Her bir ürün için ayrı ayrı grafikler çizilerek verilerin belirli bir trend ya da mevsimsellik gösterip göstermediği belirlenmeye çalışılmıştır.




Şekil 6.1: Ürün 1'e ait gerçekleşen satış miktarları

Şekil 6.1'de görüldüğü üzere Ürün 1 için gerçekleşen siparişler incelendiğinde göze çarpan bir trend veya mevsimsellik söz konusu değildir. Sipariş miktarında dalgalanmalar mevcuttur ancak yılın belli dönemleri (mevsim, ay, 6 ay vb.) için düzenli bir periyottan bahsetmek mümkün değildir. Dolayısıyla mevsimsellik eğilimi çok net değildir. Talepteki değişkenlik grafikten açıkça görülebilmektedir.




Şekil 6.2: Ürün 2'ye ait gerçekleşen satış miktarları

Şekil 6.2 incelendiğinde Ürün 2 için yer yer kısa dönem yükseliş trendi izlenimi ve yer yer dalgalanma görülse de bu ürün için de belirgin bir trend ya da mevsimsellikten bahsetmek mümkün görünmemektedir. Talep miktarı genel olarak 2.000-12.000 koli/ay bandında seyir gösterse de dönemsel olarak aşağı ve yukarı yönlü sert kırılımlar gerçekleşebilmektedir.



Şekil 6.3: Ürün 3'e ait gerçekleşen satış miktarları

Şekil 6.3 incelendiğinde Ürün 3 için sert düşüş ve artış eğilimleri gözlenebilmektedir. Bu durum Ürün 1'de de bahsedilen ve önceki bölümlerde detaylı olarak anlatılan talep belirsizliğine ek sektörel belirsizliklerden kaynaklanmaktadır. Eldeki veriler bu eğilimleri açıklamaya yeterli olmazken ancak yapay zekâ tabanlı bir algoritma ile bu verilerin tahmin için kullanılabileceği öngörülmüştür.



Şekil 6.4: Ürün 4'e ait gerçekleşen satış miktarları

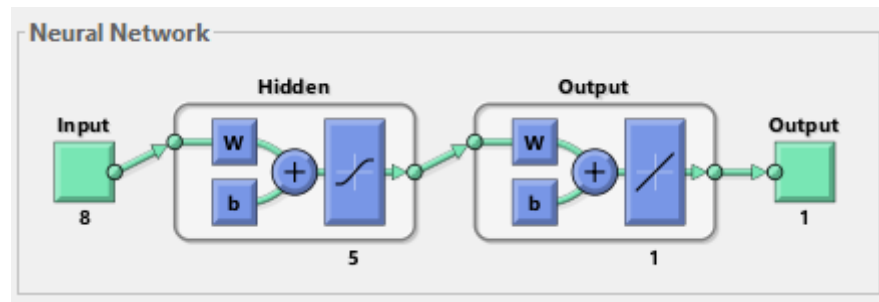
Şekil 6.4 incelendiğinde yine yer yer stabil yer yer dalgalı bir sipariş grafiği görülmektedir. Önceki ürünlerde olduğu gibi talepte öngörülemeyen bir değişkenlik söz konusudur.

İncelenen 4 ürüne ait veriler genel olarak değerlendirildiğinde, özetle bu ürünlere olan talebin değişkenlik gösterdiği, talebin belirgin bir trend veya mevsimsellik sergilemediği söylenebilir.

6.3 Yapay Sinir Ağları ile Tahmin Çalışması

Önceki bölümde verilerin analiz edildiği 4 ürün için önce yapay sinir ağları kullanılarak tahmin çalışması yürütülmüştür. Tahmin için MATLAB programının Nftool aracından yararlanılmıştır.

YSA ile tahmin yapılırken öncelikli olarak nasıl bir ağ kullanılacağı ve bu ağdaki parametre değerlerinin ne olacağı belirlenmesi gerekir. Kullanılacak yapay sinir ağının yapısı belirlenirken önceki çalışmalar referans alınarak ileri beslemeli çok katmanlı bir yapay sinir ağı kullanılmıştır. Bir önceki bölümde anlatıldığı üzere bu ağlar önceki katmandan gelen verilerle beslenirler. Çalışmada kullanılan yapay sinir ağının yapısı Şekil 6.5'te gösterilmiştir. Şekil 6.5'den de görüleceği üzere YSA bir gizli katman ve bir çıktı katmanı olmak üzere iki katmandan oluşmaktadır. Gizli katmanda aktivasyon fonksiyonu olarak Sigmoid fonksiyonu, çıkış katmanında ise doğrusal fonksiyon kullanılmıştır. Öğrenme metodu olarak Levenberg Marquardt metodundan yararlanılmıştır. Levenberg Marquardt metodu ileri beslemeli ağlarda en hızlı öğrenme yöntemi olduğu için bu çalışmada da Levenberg Marquardt öğrenme yöntemi kullanılmıştır.



Şekil 6.5: Çalışmada kullanılan Yapay Sinir Ağı modeli

Çalışmada kullanılacak olan yapay sinir ağı modeli belirlendikten sonra eldeki verilerin ne kadarının eğitileceği ne kadarının test verisi olarak kullanılacağı ve ağda kullanılacak nöron sayısı gibi parametrelerin belirlenmesi için parametre optimizasyonu yapılmıştır. Parametre optimizasyonu sonucunda en iyi değerleri

üreten parametrelerle tahmin gerçekleştirilmiştir. Deney tasarımı aşamasından önce veriler Denklem (6.1) yardımı ile normalize edilmiştir.

$$X_{normalized} = \frac{x-x_{min}}{x_{max}-x_{min}} \quad (6.1)$$

6.3.1 Parametre Optimizasyonu

Yapay sinir ağları ile öğrenmenin gerçekleşebilmesi için verilerin eğitim, doğrulama ve test grubu olmak üzere 3 gruba ayrılması gerekmektedir. Eldeki verilerin ne kadarının hangi gruba dağıtılacağına belirlenmesi ağına efektif bir şekilde öğrenmesi ve doğru tahminler yapması açısından önemli bir aşamadır. Bu nedenle 3 farklı yüzdelik dilim (60-20-20, 70-15-15, 80-10-10) belirlenerek ağına hangi yüzdelik diliminde en iyi sonuçlar verdiği tespit edilmiştir. Benzer şekilde ağda kullanılan nöron sayısı da ağına öğrenme düzeyini etkileyen önemli parametrelerden biridir. Ağda kullanılacak nöron sayısı için de 5, 10, 15 ve 20 şeklinde 4 farklı değer belirlenmiş ve en iyi nöron sayısı tespit edilmeye çalışılmıştır. Bu iki parametre ile 2 faktörlü tam faktöriyel bir deney tasarımı gerçekleştirilmiştir. Deney tasarımı kapsamında kullanılan parametreler Tablo 6.2’de verilmiştir.

Her bir parametre kombinasyonu için kırk kez deneme yapılmış ve her bir denemenin sonuçları kaydedilmiştir. Deney tasarımı sonuçları değerlendirilirken istatistiksel performans göstergesi olarak en düşük Ortalama Hata Kare (OHK) değeri dikkate alınmış ve en düşük OHK değerini veren parametre seti en iyi parametre seti olarak seçilmiştir.

Tablo 6.2: Deney tasarımı kapsamında kullanılan parametreler

Nöron Sayısı	Eğitim Seti (%)	Validasyon Seti (%)	Test Seti (%)
5	60	20	20
10	60	20	20
15	60	20	20
20	60	20	20
5	70	15	15
10	70	15	15
15	70	15	15
20	70	15	15
5	80	10	10
10	80	10	10
15	80	10	10
20	80	10	10

Deney tasarımı sonucunda her bir ürün için en iyi sonucu veren parametre değerleri Tablo 6.3'te verilmiştir. Bu parametre değerleri kullanılarak her bir ürün için ayrı ayrı tahmin yapılmıştır.

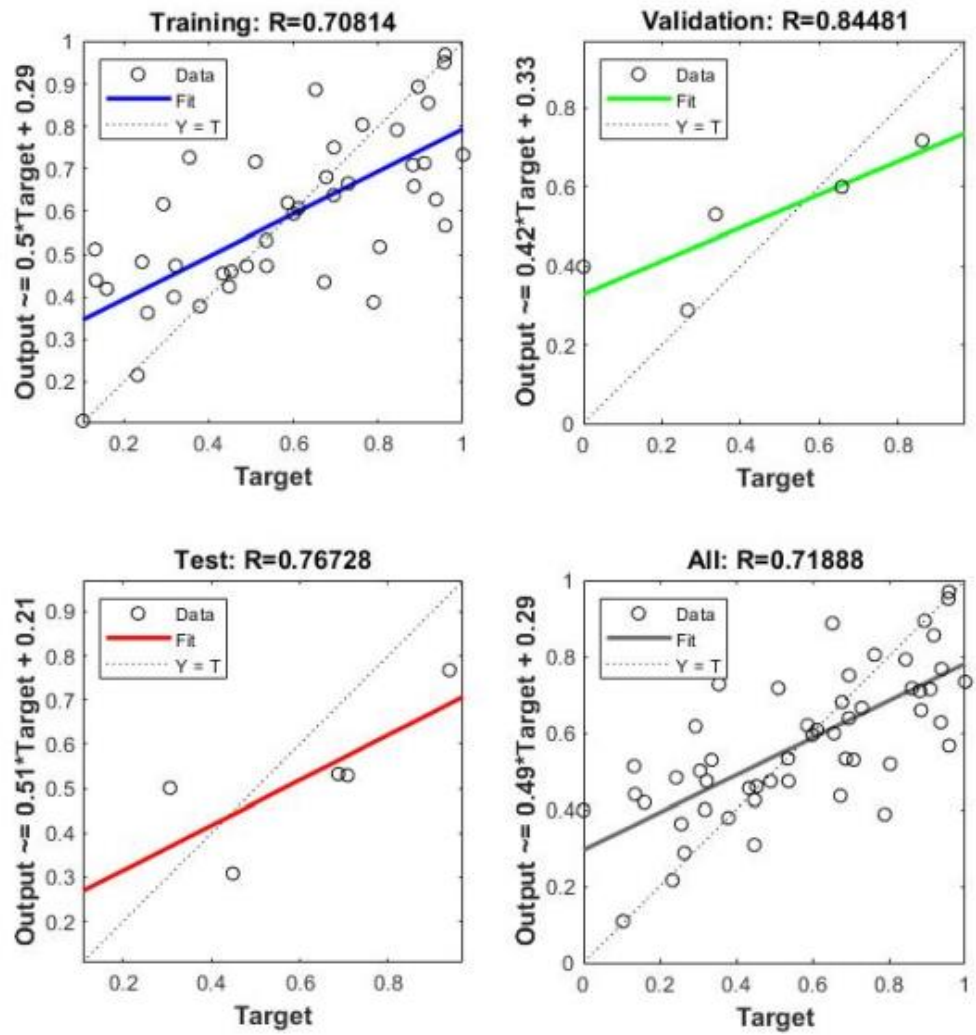
Tablo 6.3: En iyi parametre değerleri

Ürün	Nöron Sayısı	Eğitim Seti (%)	Validasyon Seti (%)	Test Seti (%)	OHK
Ürün 1	5	80	10	10	0,0127
Ürün 2	5	80	10	10	0,0079
Ürün 3	10	80	10	10	0,0013
Ürün 4	5	80	10	10	0,0220

6.3.2 YSA Sonuçları

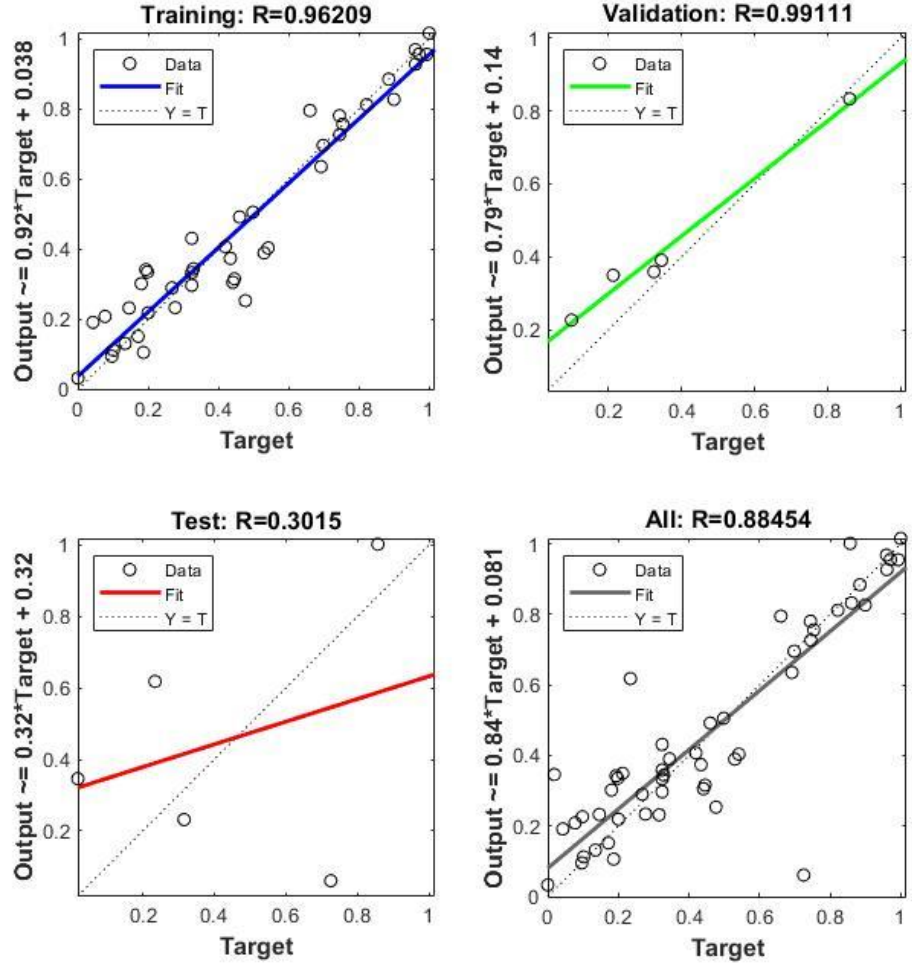
Önceki bölümde elde edilen parametre değerleri kullanılarak her bir ürün için ayrı ayrı tahmin yapılmıştır.

Şekil 6.6'da Ürün 1 için yapılan tahmine ilişkin R değerlerini gösteren grafikler görülmektedir. Grafiğe bakıldığında sinir ağının çalışması sırasında hem eğitimde hem doğrulamada hem de test aşamasında R değerinin %70 ve %84 arası değerler aldığı görülmüştür. Bu değerlerin kabul edilebilir olduğu görülmektedir.




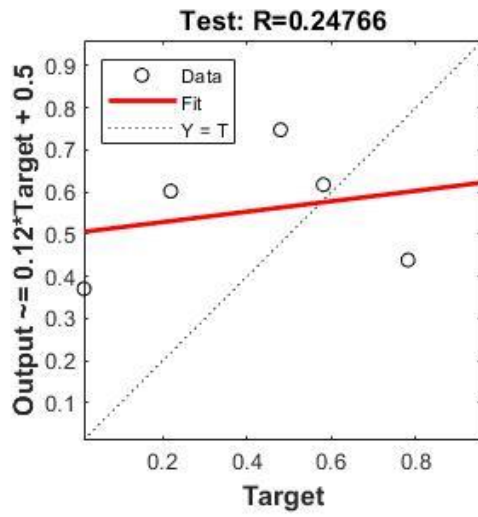


Şekil 6.6: Ürün 1 için regresyon grafiği

Şekil 6.7’de Ürün 2’ye ait regresyon grafiği görülmektedir. Genel olarak değerlendirildiğinde bu ürün için R değeri yaklaşık %89’dur. Validasyon değeri ise %99 gibi yüksek bir değerdir. Bu da YSA’nın bu ürün için tahmin gücünün Ürün 1’e göre daha iyi olduğu anlamına gelmektedir. Yani YSA bu veri setini öğrenmede daha başarılıdır ve genel olarak verilerin %89’u bu YSA modeli ile açıklanabilmektedir.

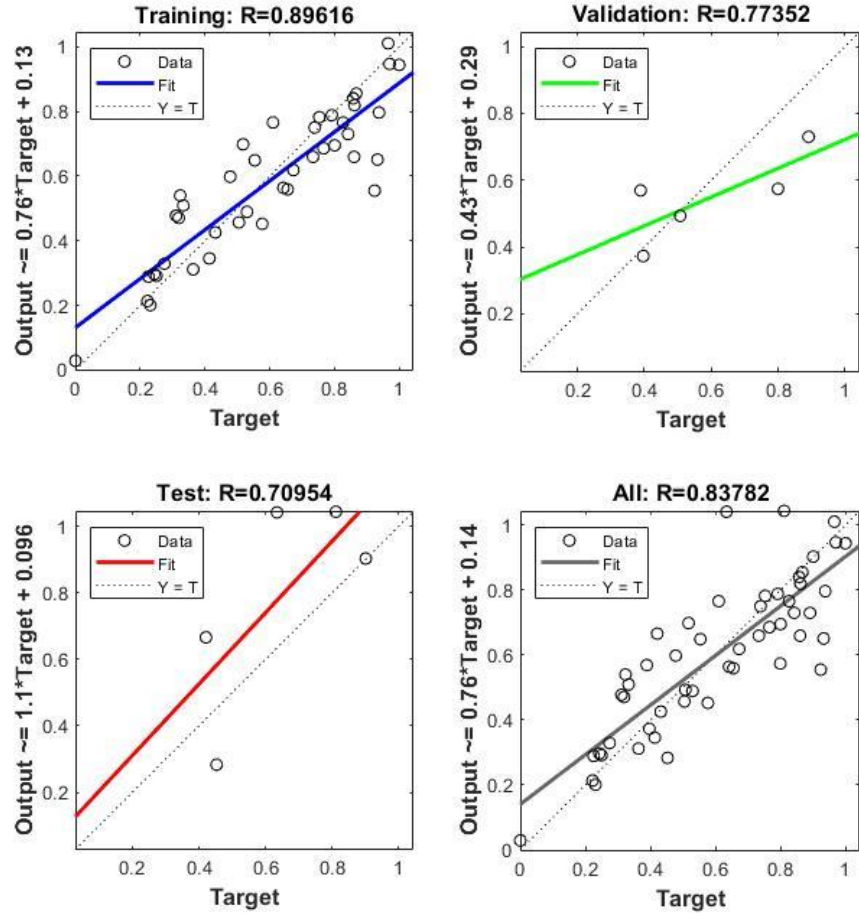


Şekil 6.7: Ürün 2 için regresyon grafiği

Benzer şekilde Ürün 3 ve Ürün 4 için R grafikleri ise sırası ile Şekil 6.8 ve Şekil 6.9’da verilmiştir. Ürün 3 için genel R değeri yaklaşık %89, Ürün 4 içinse %84’tür. Önceki ürünlerde olduğu gibi YSA modelinin ilişki oranının yüksek olduğu ve istatistiksel anlamda kabul edilebilir sonuçlar verdiği bu ürünlerde de görülmüştür.



Şekil 6.8: Ürün 3 için regresyon grafiği



Şekil 6.9: Ürün 4 için regresyon grafiği

Tablo 6.4’te her bir ürün için tahmin hataları verilmiştir. Tahmin hataları 3 farklı ölçüte göre hesaplanmıştır: Ortalama Hata Kare (OHK), Ortalama Mutlak Hata (OMH) ve Ortalama Mutlak Yüzde Hata (OMYH).

Tablo 6.4: YSA ile yapılan tahminlere ait hata değerleri

Ürün	OHK	OMH	OMYH (%)
Ürün 1	35267739	4428	3,8
Ürün 2	115172	2904	54,11
Ürün 3	1094733	721	19,45
Ürün 4	2869915	1432	30,75

6.4 Destek Vektör Regresyonu ile Tahmin Çalışması

Uygulamanın ikinci bölümünde Destek Vektör Regresyonu yöntemi ile tahmin yapılmıştır. YSA'da olduğu gibi burada da öncelikle parametre optimizasyonu için bir deney tasarımı yapılmış, bulunan optimum parametre değerleri ile 4 ürüne ait tahmin değerleri elde edilmiştir. DVR ile tahmin için MATLAB programının makine öğrenim aracı kullanılmıştır ve YSA'da olduğu gibi veriler Denklem (6.1) kullanılarak normalize edilmiştir. Verilerin %70'i eğitim için, %15'i validasyon ve geri kalan %15'i test için kullanılmıştır.

6.4.1. Parametre Optimizasyonu

Deney tasarımı sürecinde DVR yönteminin temeli olan Kernel fonksiyonu (σ), Epsilon (\mathcal{E}) ve kısıt fonksiyonu (C) parametrelerinin en iyi değerleri araştırılmıştır. Bu denemeler yine YSA'daki gibi ürün bazlı yapılmıştır. Kernel fonksiyonu için 2 değer, Epsilon için 2 değer ve kısıt fonksiyonu parametresi için 3 değer belirlenerek tam faktöryel deney tasarımı gerçekleştirilmiştir. Her bir faktörün seviyeleri Tablo 6.5'te gösterilmiştir. En iyi parametre değeri belirlenirken YSA'da olduğu gibi Ortalama Hata Kare (OHK) değerleri performans ölçütü olarak belirlenmiştir.

Tablo 6.5: Deney tasarımında kullanılan parametreler ve değerleri

	$\sigma=0,1$		$\sigma=0,2$	
	$\mathcal{E}=0,005$	$\mathcal{E}=0,01$	$\mathcal{E}=0,005$	$\mathcal{E}=0,01$
$C=80$	-	-	-	-
$C=100$	-	-	-	-
$C=120$	-	-	-	-

Her bir ürün için en küçük hata kare değerini veren parametre seti tahmin yapılırken kullanılmıştır. Bu parametre değerleri Tablo 6.6'da verilmiştir.

Tablo 6.6: En iyi parametre değerleri

Ürün	C	σ	\mathcal{E}	OHK
Ürün 1	120	0,1	0,01	0,0466
Ürün 2	80	0,1	0,005	0,3215
Ürün 3	120	0,1	0,005	0,0433
Ürün 4	100	0,1	0,01	0,0546

6.4.2 DVR Sonuçları

Önceki bölümde elde edilen parametre değerleri kullanılarak her bir ürün için ayrı ayrı tahmin yapılmıştır. Tablo 6.7’de her bir ürüne ait tahminler sonucunda elde edilen hata değerleri görülmektedir. OHK ve OMH değerleri dikkate alındığında DVR’nin Ürün 3 ve 4 için iyi tahmin sonuçları ürettiği görülürken 1 ve 2 numaralı ürünler için aynı başarıyı yakalamadığı görülmektedir.


Tablo 6.7: DVR ile yapılan tahminlere ait hata değerleri

	OHK	OMH	OMYH (%)
Ürün 1	137231390	8053	7,01
Ürün 2	10550935	2420	42,10
Ürün 3	6248869	2010	53,38
Ürün 4	8736926	2372	48,46

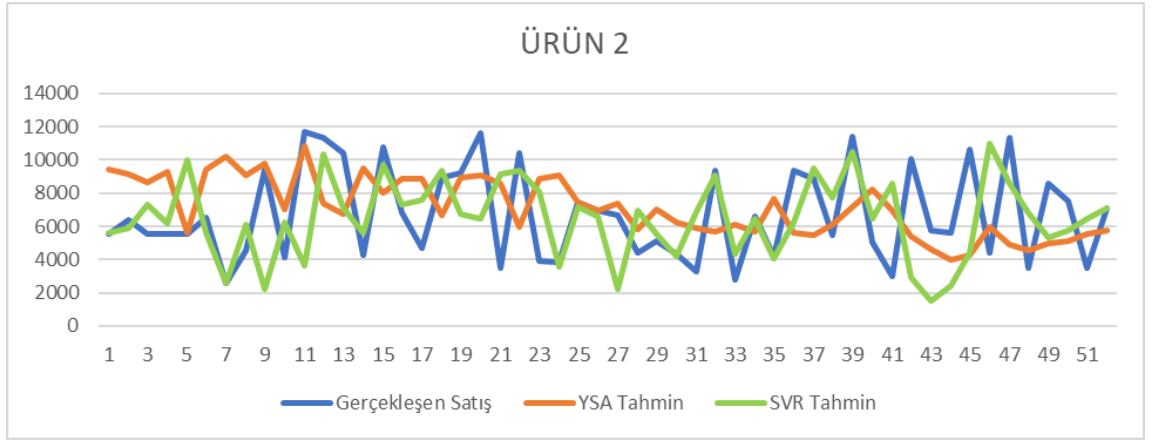
Her iki yöntemin ürün bazındaki tahmin performansı Tablo 6.8’de görülmektedir. Ayrıca her bir ürün için yapılan tahminler ile gerçekleşen satış miktarlarının karşılaştırıldığı grafikler Şekil 6.10-6.13’te verilmiştir. Grafikler ve Tablo 6.8 incelendiğinde YSA’nın tahmin performansının DVR’ye göre daha iyi olduğu görülmektedir. Yalnızca ikinci üründe OMH ve OMYH değerlerine bakıldığında DVR’nin daha iyi tahmin değerleri ürettiği ancak bu üründe de YSA’nın OHK değeri açısından DVR’den oldukça iyi olduğu görülmektedir. Sonuçlar genel olarak yorumlanacak olursa YSA’nın incelenen ürünler için DVR’den daha iyi tahminler yaptığı söylenebilir.

Tablo 6.8: Ürün bazında tahmin hataları: Yöntemlerin karşılaştırılması


Yöntem	Ürün 1			Ürün 2			Ürün 3			Ürün 4		
	OHK	OMH	OMYH (%)	OHK	OMH	OMYH (%)	OHK	OMH	OMYH (%)	OHK	OMH	OMYH (%)
YSA	76263797	7527	6,5	115172	2904	54,11	109473	721	19,45	286991	1432	30,75
DVR	137231390	8053	7,01	1055093	2420	42,10	6248869	2010	53,38	8736926	2372	48,46




Şekil 6.10: Gerçekleşen ve tahmin edilen satış miktarları-ÜRÜN 1



Şekil 6.11: Gerçekleşen ve tahmin edilen satış miktarları-ÜRÜN 2



Şekil 6.12: Gerçekleşen ve tahmin edilen satış miktarları-ÜRÜN 3



Şekil 6.13: Gerçekleşen ve tahmin edilen satış miktarları-ÜRÜN 4

7. SONUÇ VE ÖNERİLER

Küreselleşen dünya koşullarında meydana gelen talep değişimleri ve ürün çeşitliliği firmaları daha efektif planlar yapmaya zorlamaktadır. Gerek stratejik öneme sahip uzun vadeli planlarda gerekse orta ve kısa vadeli planlarda firmaların gelecek için öngörülerde bulunabilmeleri ve bu öngörüler ışığında planlar yapabiliyor olmaları firmaların uzun dönemde piyasada tutunabilmelerinde önem arz etmektedir. Bu bağlamda belirsizlik altında talep tahmini konusu önemli bir araştırma alanı olarak karşımıza çıkmaktadır.

Bu tez çalışması kapsamında belirsizliğin yoğun olarak yaşandığı gıda sektöründeki bir işletme için yapay zekâ teknikleri kullanılarak talep tahmin çalışması yürütülmüştür. Talep değişkenliğinin ve belirsizliğinin fazla olduğu durumlarda yapay zekâ tekniklerinin geleneksel yöntemlerden daha iyi sonuçlar verdiği literatürden de bilinmektedir. O nedenle bu çalışmada Yapay Sinir Ağları ve Destek Vektör Regresyonu yöntemleri kullanılarak tahmin yapılmıştır.

Çalışma kapsamında seçilen 4 ürüne ait 52 aylık veriler analiz edilerek sırası ile YSA ve DVR yöntemleri ile tahmin yapılmıştır. Yöntemler uygulanmadan önce her bir yöntem için ayrı ayrı deney tasarımı yapılmış ve parametre optimizasyonu gerçekleştirilmiştir. Böylelikle uygulanan yöntemlerin tahmin gücünün artırılması sağlanmıştır. Tahmin performansı Ortalama Mutlak Hata, Ortalama Mutlak Yüzde Hata ve Ortalama Hata Kare ölçütlerine göre değerlendirilmiş ve yöntemler bu performans ölçütlerine göre karşılaştırılmıştır. Elde edilen sonuçlar yöntemlerin performansının üründen ürüne ve dikkate alınan hata ölçütüne göre değiştiğini ancak genel olarak Yapay Sinir Ağlarının Destek Vektör Regresyonuna göre daha başarılı tahminler yaptığını göstermiştir.

Bu çalışma kapsamında iki yapay zekâ tekniğinin belirsiz koşullar altında tahmin performansı karşılaştırılmıştır. Gelecekte bu karşılaştırmalara gri tahmin ve çok değişkenli uyarlanabilir regresyon eğrileri gibi belirsizlikte birden fazla değişkeni göz önünde bulunduran yöntemler eklenebilir.

8. KAYNAKLAR

Alada, A. D., İktisat Felsefesi ve Belirsizlik, İstanbul:Bağlam Yayıncılık (2000).

Babu, C. N. ve Reddy, B. E., "A moving-average filter based hybrid ARIMA-ANN model for forecasting time series data", *Applied Soft Computing*, 27, 27-38, (2014).

Bakımlı, E., "İktisatta Belirsizlik Kavramı ve Enflasyon Belirsizliğinin İç Borçlanma Faizlerindeki Risk Primine Etkisi: Türkiye Örneği (1990-2003)", Yayımlanmamış Yüksek Lisans Tezi, Muğla, (2004).

Chen-Ritzo, C.-H., Ervolina, T., Harrison, T. P., ve Gupta, B., "Sales and operations planning in systems with order configuration uncertainty", *European Journal of Operational Research*, 205(3), 604-614, (2010).

Ching-Chin, C., Ieng, A. I. K., Ling-Ling, W. ve Ling-Chieh, K., "Designing a decision-support system for new product sales forecasting", *Expert Systems with Applications*, 37(2), 1654-1665, (2010).

Doganis, P., Alexandridis, A., Patrinos, P. ve Sarimveis, H., "Time series sales forecasting for short shelf-life food products based on artificial neural networks and evolutionary computing", *Journal of Food Engineering*, 75, 196-204, (2006).

Dosi, G., ve Egidi, M., "Substantive and procedural uncertainty", *Journal of Evolutionary Economics*, 1, 49-84, (1991).

Drucker, H., Burges, C. J. C., Kaufman, L., Smola, A. ve Vapnik, V., "Support vector regression machines", *Advances in Neural Information Processing Systems*, 9, 155-161, (1997).

Du, X. F., Leung, S. C. H., Zhang, J. L. ve Lai, K. K., "Demand forecasting of perishable farm products using support vector machine", *Int. J. Systems Science*, 44(3), 556-567, (2013).

Erdoğan, E. B. Ç. "Rüzgar Hız Ve Enerji Verilerinin Tahmini İçin Kaotik Yaklaşımla Birlikte Destek Vektör Regresyonunun Kullanımı", Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi Fen Bilimleri Enstitüsü, Meteoroloji Mühendisliği Anabilim Dalı, İstanbul, (2019).

Fildes, R., ve Kingsman, B. "Incorporating demand uncertainty and forecast error in supply chain planning models", *J Oper Res Soc*, 62(3), 483-500, (2011).

Guo, H., Wang, X. ve Gao, Z., "Uncertain linear regression model and its application", *Journal of Intelligent Manufacturing*, 28(3), 559-564, (2017).

Guo, Z. X., Wong, W. K., ve Li, M., "A multivariate intelligent decision-making model for retail sales forecasting", *Decision Support Systems*, 55(1), 247-255, (2013).

Haykin, S., *Neural Networks and Learning Machines*, Hamilton, Ontario, Canada, Pearson, (2009).

Huang, T.-M., Kecman, V., ve Kopriva, I., *Kernel Based Algorithms for Mining Huge Data Sets*, Springer-Verlag Berlin Heidelberg, Vol. 17, (2006).

Jaipuria, S., ve Mahapatra, S. S., "An improved demand forecasting method to reduce bullwhip effect in supply chains", *Expert Systems with Applications*, 41, 2395-2408, (2014).

Kandanand, K., "Consumer product demand forecasting based on artificial neural network and support vector machine", *World Academy of Science, Engineering and Technology, Int. J. Social, Behavioral, Educational, Economic, Business and Industrial Engineering*, 6(3), 313-316, (2012).

Kecman, V., *Learning and Soft Computing: Support Vector Machines, Neural Networks and Fuzzy Logic Models [Elektronik Sürüm]*, MIT Press (2001).

Lavoie, M., *Foundations of post-Keynesian Economic Analysis*, Edward Elgar Publishing, (1994).

Lu, C.-J., Lee, T.-S. ve Lian, C.-M., "Sales forecasting for computer wholesalers: A comparison of multivariate adaptive regression splines and artificial neural networks", *Decision Support Systems*, 54, 584-596, (2012).

Maltarollo, V. G., Honório, K. M. ve Ferreira da Silva, A. B., "Applications of Artificial Neural Networks in Chemical Problems", In: Suzuki, K. (eds), Intech, (2013).

McCarthy, T. M., Davis, D. F., Golicic, S. L. ve Mentzer, J. T., "The Evolution of Sales Forecasting Management: A 20-Year Longitudinal Study of Forecasting Practices", *Journal of Forecasting*, 25(5), 303-324, (2006).

McCulloch, W. S., ve Pitts, W., "A logical calculus of the ideas immanent in nervous activity", *The Bulletin of Mathematical Biophysics*, 5(4), 115-133, (1943).

Mor, R. S., Jaiswal, S. K., ve Singh, S. "Demand Forecasting of the Short-Lifecycle Dairy Products", In: Chahal H., Jyoti J., Wirtz J. (eds) *Understanding the Role of Business Analytics*, Springer, Singapore, 87-117, (2019).

Murphy, M. D., O'Mahony, M. J., Shalloo, L., French, P. ve Upton, J., "Comparison of modeling techniques for milk-production forecasting", *Journal of Dairy Science*, 97(6), 3352-3363, (2014).

Olgun, S., "Tedarik zinciri yönetiminde talep tahmini yöntemleri ve yapay zeka tabanlı bir talep tahmini modelinin uygulanması". Yüksek Lisans Tezi, *İstanbul Üniversitesi Fen Bilimleri Enstitüsü*, Endüstri Mühendisliği Anabilim Dalı, İstanbul, (2009).

Özkan, Y., *Veri Madenciliği Yöntemleri*. İstanbul: Papatya Bilim (2008).

Öztemel, E., *Yapay Sinir Ağları*. İstanbul: Papatya Yayıncılık (2012).

Parimita, E. ve Arora, E. P., "Sales forecasting of milk and milk products by quantitative techniques-A case study", *Int. J. Multidisciplinary Approach and Studies*, 2(1), 305-310, (2015).

Petropoulos, F., Hyndman, R. J. ve Bergmeir, C., "Exploring the sources of uncertainty: Why does bagging for time series forecasting work?", *European Journal of Operational Research*, 268(2), 545-554, (2018).

Raju, Y., Kang, P. S., Moroz, A., Clement, R., Hopwell, A. ve Duffy, A., "Investigating the demand for short-shelf life food products for SME wholesalers", *World Academy of Science, Engineering and Technology Int. J. Economics and Management Engineering*, 9(6), 2051-2055, (2015).

Runde, J., "Clarifying Frank Knight's discussion of the meaning of risk and uncertainty", *Cambridge Journal of Economics*, 22(5), 539-546, (1998).

Sarı, M. "Yapay Sinir Ağları Ve Bir Otomotiv Firmasında Satış Talep Tahmini Uygulaması". Yüksek Lisans Tezi, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*, Endüstri Mühendisliği Anabilim Dalı, Sakarya, (2016).

Sertaş, Z. S., "Türkiye'de perakende sektöründe talebi etkileyen etmenler ve yapay sinir ağlarıyla talep tahmini uygulaması", Yüksek Lisans Tezi, *Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü*, Endüstri Mühendisliği Anabilim Dalı, İstanbul, (2011).

Stigler, G. J., "The economics of information", *Journal of Political Economy*, 69(3), 213-225, (1961).

Sun, Z.-L., Choi, T.-M., Au, K.-F., ve Yu, Y., "Sales forecasting using extreme learning machine with applications in fashion retailing", *Decision Support Systems*, 46(1), 411-419, (2008).

Tabrizi, B. H., ve Ghaderi, S. F., "Sales forecasting of a dairy product manufacturing company: a comparative study of autoregressive integrated moving average and local linear neuro-fuzzy models", *Int. J. Services and Operations Management*, 24(4), 531-547, (2016).

Uslu, M. Veri Bilimci. Yapay Sinir Ağları (YSA) Nedir – Bölüm 2 Web adresi: <http://veribilimci.org/yapay-sinir-aglari-ysa-nedir-bolum-2/>, (2016).

Vapnik, V., *The Nature of Statistical Learning Theory*, Springer Verlag New York Inc. (1995).

Veiga, C. P. D., Veiga, C. R. P. D., Catapan, A., Tortato, U., ve Silva, W. V. D., "Demand forecasting in food retail: A comparison between the Holt-Winters and ARIMA models", *WSEAS Transactions on Business and Economics*, 11, 608-614, (2014).

Villegasa, M. A., Pedregala, D. J., ve Trapero, J. R., "A Support Vector Machine For Model Selection in Demand Forecasting Applications", *Computers & Industrial Engineering*, 121, 1-7, (2018).

Wang, Z. ve Xue, X., "Multi-class support vector machine", In: Ma, Y. Guo, G. (eds) *Support Vector Machines Applications*, 23-48, (2014).

Yanık, E., "İş makineleri sektöründe yapay sinir ağları ile talep tahmini uygulaması". Yüksek Lisans Tezi, *Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü*, Endüstri Mühendisliği Anabilim Dalı, Kırıkkale, (2019).

Zontul, M., ve Yangın, A., "Yapay Sinir Ağı Teknikleri Kullanarak Eğitim Yayıncılığı Sektöründe Veri Madenciliği", *AURUM Mühendislik Sistemleri ve Mimarlık Dergisi*, 1(2), 1-15, (2017).

9. ÖZGEÇMİŞ

Adı Soyadı : Feyza Çoban

Doğum Yeri ve Tarihi : Kastamonu 03.03.1992

Lisans Üniversite : Süleyman Demirel Üniversitesi Mühendislik
Fakültesi Endüstri Mühendisliği Bölümü

Y. Lisans Üniversite : Pamukkale Üniversitesi

Elektronik posta : feyzacoban37@gmail.com

İletişim Adresi : Atalar Mah. 928 Sok. Kırmızı Apart.
Pamukkale/Denizli