



**PERAKENDE HAZIR GİYİM ENDÜSTRİSİNDE  
YAPAY ZEKA YÖNTEMLERİ İLE TALEP  
TAHMİNİ**

**İlker GÜVEN**

**2020  
YÜKSEK LİSANS TEZİ  
ENDÜSTRİ MÜHENDİSLİĞİ**

**Tez Danışmanı  
Dr. Öğr. Üyesi Fuat ŞİMŞİR  
Doç. Dr. Özer UYGUN**

**PERAKENDE HAZIR GİYİM ENDÜSTRİSİNDE YAPAY ZEKA  
YÖNTEMLERİ İLE TALEP TAHMİNİ**

**İlker GÜVEN**

**T.C.  
Karabük Üniversitesi  
Lisansüstü Eğitim Enstitüsü  
Endüstri Mühendisliği Anabilim Dalında  
Yüksek Lisans Tezi  
Olarak Hazırlanmıştır**

**Tez Danışmanı  
Dr. Öğr. Üyesi Fuat ŞİMŞİR  
Doç. Dr. Özer UYGUN**

**KARABÜK  
Haziran 2020**

İlker GÜVEN tarafından hazırlanan “PERAKENDE HAZIR GİYİM ENDÜSTRİSİNDE YAPAY ZEKA YÖNTEMLERİ İLE TALEP TAHMİNİ” başlıklı bu tezin Yüksek Lisans Tezi olarak uygun olduğunu onaylarım.

Dr. Öğr. Üyesi Fuat ŞİMŞİR .....  
Tez Danışmanı, Endüstri Mühendisliği Anabilim Dalı

Doç. Dr. Özer UYGUN .....  
Tez Danışmanı, Endüstri Mühendisliği Anabilim Dalı (SAÜ)

Bu çalışma, jürimiz tarafından Oy Birliği ile Endüstri Mühendisliği Anabilim Dalında Yüksek Lisans tezi olarak kabul edilmiştir. 08/06/2020

<u>Ünvanı, Adı SOYADI (Kurumu)</u>	<u>İmzası</u>
Başkan : Doç. Dr. Muharrem DÜĞENCİ (KBÜ)	.....
Üye : Dr. Öğr. Üyesi Fuat ŞİMŞİR (KBÜ)	.....
Üye : Doç. Dr. Özer UYGUN (SAÜ)	.....
Üye : Dr. Öğr. Üyesi Çağrı SEL (KBÜ)	.....
Üye : Dr. Öğr. Üyesi Tuğba TUNACAN (Bolu AİBÜ)	.....

KBÜ Lisansüstü Eğitim Enstitüsü Yönetim Kurulu, bu tez ile, Yüksek Lisans derecesini onamıştır.

Prof. Dr. Hasan SOLMAZ .....  
Lisansüstü Eğitim Enstitüsü Müdürü

*“Bu tezdeki tüm bilgilerin akademik kurallara ve etik ilkelere uygun olarak elde edildiğini ve sunulduğunu; ayrıca bu kuralların ve ilkelerin gerektirdiği şekilde, bu çalışmadan kaynaklanmayan bütün atıfları yaptığımı beyan ederim.”*

İlker GÜVEN

## ÖZET

**Yüksek Lisans Tezi**

### **PERAKENDE HAZIR GİYİM ENDÜSTRİSİNDE YAPAY ZEKA YÖNTEMLERİ İLE TALEP TAHMİNİ**

**İlker GÜVEN**

**Karabük Üniversitesi**

**Lisansüstü Eğitim Enstitüsü**

**Endüstri Mühendisliği Anabilim Dalı**

**Tez Danışmanı:**

**Dr.Öğr.Üyesi Fuat ŞİMŞİR**

**Doç. Dr. Özer UYGUN**

**Haziran 2020, 142 sayfa**

Bu çalışmada perakende hazır giyim endüstrisindeki ürün çeşitliliği dikkate alınarak yapay zeka yöntemleri kullanarak minimum hata oranı ile satış talep tahmini yapılması amaçlanmıştır. Klasik yöntemlerin dikkate alamadığı birçok değişkeni yapay zeka teknikleri ile modele dahil ederek tahminin doğruluğu artırılmıştır. Bu bağlamda yapay zeka tekniklerinden yapay sinir ağları (YSA), destek vektör makineleri (DVM) ve rastgele ormanlar (RO) modelleri kurularak veri setinden çıkarımlar yapılmıştır. Modellerin kurulması aşamasında tahmini yapılan ürünlerin renk detaylarının olduğu ve olmadığı iki farklı veri seti hazırlanmış ve tahmin işlemi gerçekleştirilmiştir. Böylece yapay zeka talep tahmin yöntemleri arasında karşılaştırma yapma imkanı oluşturulmuştur. Çalışma kapsamında 20 yılı aşkın süredir sektörde faaliyet gösteren bir perakende hazır giyim firmasının 2014 49. hafta ile 2018 52. haftaları arasında kadın ve erkek ürün grubunda yaptığı satışlar veri seti

olarak kullanılmıştır. Giyim endüstrisinde sık görülen satışa çıkan ürünlerin renklerinin belirli bir kısmının diğer renklerden önce bitmesi durumunda satışın tek bir renge yoğunlaşması, diğer renklerin satış görememesi gibi tahmini olumsuz etkileyebilecek durumların değerlendirilmesi için ürünlerin renk detayları çalışma kapsamına alınmıştır. Ürünlerin tek bir veri setinde mi yoksa ayrı ayrı mı tahmin edilmesinin daha iyi olduğu sorusuna cevap bulabilmek için her bir ürün tek tek olarak ayrıca tahmin edilmiştir.

Yapılan tahmin çalışmaları sonucunda hangi yöntemin daha iyi sonuçlar verdiği belirlenmiş, ayrıca yöntemlerin sonuçları karşılaştırılarak sonuçların güvenilirliği artırılmıştır. Yöntemlerin karşılaştırılmasında literatürde en çok kullanılan performans kriterlerinden ortalama mutlak hata, ortalama karelerin hatası, hataların ortalama karekökü, ortalama mutlak yüzde hata ve  $R^2$  kriterleri dikkate alınmıştır. Çalışma kapsamında 14 farklı veri seti kullanılmış, renk detaylı ve renk detaysız olmak üzere toplamda 84 model kurulmuştur. Elde edilen sonuçlara göre 14 veri setinin 8'inde YSA renk detaysız modeller diğer modellere göre daha iyi sonuçlar vermiştir. YSA renksiz verilerde 14 modelden 11'inde daha başarılı iken, DVM ise 13 modelde renk detaylı verilerde daha iyi sonuçlar vermiştir. RO modelleri ise renk detaylı ve renk detaysız verilerde benzer sonuçlar vermiştir.

**Anahtar Sözcükler :** Perakende talep tahmini, yapay sinir ağları, destek vektör makineleri, rastgele ormanlar, hazır giyim, tekstil,

**Bilim Kodu** : 90619

## **ABSTRACT**

**M. Sc. Thesis**

### **DEMAND FORECASTING WITH ARTIFICIAL INTELLIGENCE METHODS IN RETAIL APPAREL INDUSTRY**

**İlker GÜVEN**

**Karabük University  
Institute of Graduate Programs  
Department of Industrial Engineering**

**Thesis Advisor:**

**Assist.Prof.Dr. Fuat ŞİMŞİR**

**Assoc.Prof.Dr. Özer UYGUN**

**June 2020, 142 pages**

In this study, product variety has been taken into account and sales demand forecasting has been performed by using artificial intelligence to minimize error rate in retail garment industry. Forecasting accuracy has been increased by including artificial intelligence methods in the model which traditional demand forecasting methods disregard. In this context, artificial intelligence models such as artificial neural networks (ANN), support vector machines (SVM) and random forests (RF) have been established and inferences from the data set have been made. During the establishment of the models, two different data sets with and without color details of the products were prepared and the estimation process was carried out. Thus, the opportunity to make comparisons between artificial intelligence demand forecasting methods has been created. Within the scope of the study, sales made in the women's and men's product group between 2014 49th week and 2018 52th week were used as

data set from the company which is operating in the retail garment industry for more than 20 years. The common situation has been observed in the apparel industry such as, some of the colors finish before other colors and then sales are redirected on a single color, thus color details of the products has been included in the study in order to evaluate the situations that may negatively affect the forecast. Each product has been individually estimated to answer the question of whether it is better to estimate whether the products are in a single data set or separately.

As a result of this forecasting study, it has been determined which method gave the best results and the reliability of the results have been increased by comparing the results of the methods. In the comparison of methods, mean absolute error, mean square error, root mean square error, mean absolute percentage error and  $R^2$  criteria has been taken into consideration. In the context of this study, 14 different data sets were used and 84 different models were established with and without color details. Obtained results show that ANN without color model had better results than other models. ANN was more successful in 11 models out of 14 for the datasets without color, while SVM was better in 13 models for the datasets with color. RF models, on the other hand, had similar results for the datasets with and without color detail.

**Key Word** : Retail demand forecasting, artificial neural networks, support vector machines, random forests, apparel, textile.

**Science Code** : 90619



## TEŐEKKÜR

Bu tez alıőmasının planlanmasında, araőtırılmasında, yürütülmesinde ve oluşumunda ilgi ve desteęini esirgemeyen, engin bilgi ve tecrübelerinden yararlandığım, yönlendirme ve bilgilendirmeleriyle alıőmamı bilimsel temeller ışığında şekillendiren sayın hocam Dr.Öęr.Üyesi Fuat ŐİMŐİR'e ve bilgi birikimiyle beni aydınlatan sayın Do.Dr. Özer UYGUN'a sonsuz teőekkürlerimi sunarım.

Sevgilerini ve desteklerini hiçbir zaman esirgemeyen ve her daim yanımda olan sevgili annem Firdes GÜVEN'e, babam Mehmet GÜVEN'e ve kardeşlerim Sinan ile Samet Arda'ya tüm kalbimle teőekkür ederim.

## İÇİNDEKİLER

	<u>Sayfa</u>
KABUL.....	ii
ÖZET.....	iv
ABSTRACT.....	vi
TEŞEKKÜR.....	viii
İÇİNDEKİLER .....	ix
ŞEKİLLER DİZİNİ.....	xiii
ÇİZELGELER DİZİNİ .....	xvi
SİMGELER VE KISALTMALAR DİZİNİ .....	xviii
BÖLÜM 1 .....	1
GİRİŞ .....	1
BÖLÜM 2 .....	4
HAZIR GİYİM ENDÜSTRİSİ .....	4
2.1. DÜNYADA HAZIR GİYİM VE TEKSTİL .....	5
2.2. TÜRKİYE’DE HAZIR GİYİM VE TEKSTİL .....	8
2.3. HAZIR GİYİM SEKTÖRÜNDE TALEP TAHMİNİ .....	13
2.3.1. Talep Tahminin Gerekliliği ve Önemi.....	14
2.3.2. Talep Tahminin Zorlukları .....	14
2.4. LİTERATÜR TARAMASI.....	15
BÖLÜM 3 .....	26
YAPAY ZEKA İLE TALEP TAHMİN YÖNTEMLERİ.....	26
3.1. YAPAY SINIR AĞLARI.....	26
3.1.1. Yapay Sinir Ağları Temel Kavramlar.....	26
3.1.2. Yapay Sinir Ağlarının Tarihi Ve Özellikleri.....	29
3.1.2.1. Yapay Sinir Ağlarının Avantajları ile Dezavantajları .....	31
3.1.2.2. Yapay Sinir Ağlarının Temel Yapısı Ve Bileşenleri.....	33

	<b><u>Sayfa</u></b>
3.1.3.1. Girdi Katmanı .....	35
3.1.3.2. Ağırlıklar .....	35
3.1.3.3. Gizli Katman .....	35
3.1.3.4. Birleştirme Fonksiyonu.....	36
3.1.3.5. Transfer Fonksiyonu .....	38
3.1.3.6. Çıktı Katmanı.....	40
3.1.4. Yapay Sinir Ağı Mimarileri .....	40
3.1.4.1. İleri Beslemeli Yapay Sinir Ağları .....	41
3.1.4.2. Geri Beslemeli Yapay Sinir Ağları .....	44
3.1.5. Yapay Sinir Ağı Öğrenme Algoritmaları .....	47
3.1.5.1. Danışmanlı Öğrenme .....	48
3.1.5.2. Danışmansız Öğrenme .....	49
3.1.5.3. Takviyeli Öğrenme .....	50
3.1.6. Yapay Sinir Ağı Öğrenme Kuralları .....	51
3.1.6.1. Hebb Öğrenme Kuralı.....	51
3.1.6.2. Hopfield Öğrenme Kuralı .....	51
3.1.6.3. Kohonen Öğrenme Kuralı.....	52
3.1.6.4. Delta Öğrenme Kuralı.....	53
3.2. DESTEK VEKTÖR MAKİNELERİ.....	53
3.2.1. Destek Vektör Makineleri - Sınıflandırma .....	55
3.2.1.1. Maksimum Marj Destek Vektör Makineleri.....	55
3.2.1.2. Yumuşak Marj Destek Vektör Makineleri.....	58
3.2.1.3. Doğrusal Olmayan Destek Vektör Makineleri .....	60
3.2.2. Destek Vektör Makineleri – Regresyon .....	61
3.2.2.1. Destek Vektör Makineleri – Doğrusal Regresyon .....	62
3.2.2.2. Destek Vektör Makineleri – Doğrusal Olmayan Regresyon .....	63
3.3. RASTGELE ORMANLAR.....	64
3.3.1. Rastgele Ormanlar Algoritması .....	65
3.3.2. Bağımsız Değişkenlerin Önem Derecesi .....	67
3.3.3. Değişkenler Arası Yakınlık .....	67
3.3.4. Kayıp Verilerin Tahmini.....	68

	<b><u>Sayfa</u></b>
BÖLÜM 4 .....	69
UYGULAMA .....	69
4.1. UYGULAMANIN YAPILDIĞI FİRMA.....	69
4.2. ÇALIŞMANIN KAPSAMI VE VERİ SETİ.....	70
4.3. UYGULAMA ARAÇLARI .....	74
4.3. TAHMİN ANALİZLERİ .....	74
4.3.1. Tahmin Performans Kriterleri.....	75
4.3.2. Yapay Sınır Ağı Tahmin Uygulaması .....	76
4.3.2.1. Birleştirilmiş Veri Seti İçin YSA Tahmin Uygulaması - Renk Detaylı.....	79
4.3.2.2. DBR Ürünü İçin YSA Tahmin Uygulaması - Renk Detaylı .....	81
4.3.2.3. Tüm Ürünler için YSA Tahmin Sonuçları - Renk Detaylı .....	84
4.3.2.4. Birleştirilmiş Veri Seti İçin YSA Tahmin Uygulaması – Renk Detaysız .....	85
4.3.2.5. DBR Ürünü İçin YSA Tahmin Uygulaması – Renk Detaysız.....	88
4.3.2.6. Tüm Ürünler için YSA Tahmin Sonuçları – Renk Detaysız .....	91
4.3.3. Destek Vektör Makineleri Tahmin Uygulaması – Renk Detaylı.....	93
4.3.3.1. Birleştirilmiş Veri Seti İçin DVM Tahmin Uygulaması – Renk Detaylı.....	95
4.3.3.2. DBR Ürünü İçin DVM Tahmin Uygulaması – Renk Detaylı.....	97
4.3.3.3. Tüm Ürünler için DVM Tahmin Sonuçları – Renk Detaylı .....	98
4.3.3.4. Birleştirilmiş Veri Seti İçin DVM Tahmin Uygulaması – Renk Detaysız .....	100
4.3.3.5. DBR Ürünü İçin DVM Tahmin Uygulaması – Renk Detaysız ....	101
4.3.3.6. Tüm Ürünler için DVM Tahmin Sonuçları – Renk Detaysız.....	103
4.3.4. Rastgele Ormanlar Tahmin Uygulaması .....	105
4.3.4.1. Birleştirilmiş Veri Seti İçin RO Tahmin Uygulaması – Renk Detaylı.....	108
4.3.4.2. DBR Ürünü İçin RO Tahmin Uygulaması – Renk Detaylı .....	111
4.3.4.3. Tüm Ürünler için RO Tahmin Sonuçları – Renk Detaylı.....	114
4.3.4.4. Birleştirilmiş Veri Seti İçin RO Tahmin Uygulaması – Renk Detaysız .....	115
4.3.4.5. DBR Ürünü İçin RO Tahmin Uygulaması – Renk Detaysız.....	118
4.3.4.6. Tüm Ürünler için RO Tahmin Sonuçları – Renk Detaysız.....	120

	<b><u>Sayfa</u></b>
4.4. DENEYSEL SONUÇLAR.....	122
BÖLÜM 5 .....	132
SONUÇLAR VE TARTIŞMA .....	132
KAYNAKLAR .....	135
ÖZGEÇMİŞ .....	142

## ŞEKİLLER DİZİNİ

	<b><u>Sayfa</u></b>
Şekil 3.1. Yapay sinir hücresi.....	27
Şekil 3.2. Yapay sinir ağlarının yapısı.....	28
Şekil 3.3. Biyolojik sinir hücresinin yapısı .....	34
Şekil 3.4. Doğrusal transfer fonksiyonu .....	38
Şekil 3.5. Basamak transfer fonksiyonu .....	38
Şekil 3.6. Aralık transfer fonksiyonu .....	39
Şekil 3.7. Hiperbolik tanjant transfer fonksiyonu .....	39
Şekil 3.8. Sigmoid transfer fonksiyonu .....	40
Şekil 3.9. Yapay sinir ağları mimarisi.....	41
Şekil 3.10. İleri beslemeli yapay sinir ağları mimarisi.....	42
Şekil 3.11. Geri beslemeli yapay sinir ağları mimarisi. ....	44
Şekil 3.12. Danışmanlı öğrenme. ....	48
Şekil 3.13. Danışmansız öğrenme. ....	50
Şekil 3.14. Takviyeli öğrenme.....	51
Şekil 3.15. Hopfield öğrenme kuralı .....	52
Şekil 3.16. Mümkün olan tüm ayırıcı doğrulardan iki tanesi, a) geniş marja sahip ayırıcı, b) dar marja sahip ayırıcı. ....	56
Şekil 3.17. Doğrusal ayırlamayan veri seti için optimum ayırıcı hiperdüzlem. ....	59
Şekil 3.18. Doğrusal ayırlamayan verilerin doğrusal ayrılabilir hale getirilmesi a) doğrusal ayrılmayan veri, b) doğrusal ayrılmış versiyonu.....	61
Şekil 4.1. Uygulama akış şeması.....	75
Şekil 4.2. YSA için denenen ağ kombinasyonları ve RMSE performansları.....	78
Şekil 4.4. Birleştirilmiş veri için renk detaylı gözlem değerleri ve YSA tahmin değerleri.....	79
Şekil 4.3. Elde edilen renk detaylı 1 gizli katmanlı yapay sinir ağı modeli .....	80
Şekil 4.5. İlk 200 test verisi için renk detaylı gözlem ve YSA tahmin değeri. ....	81
Şekil 4.7. DBR için renk detaylı gözlem değerleri ve YSA tahmin değerleri.....	82
Şekil 4.6. DBR ürünü için renk detaylı kurulan yapay sinir ağı modeli. ....	83
Şekil 4.8. DBR ürünü ilk 200 veri için renk detaylı gözlem ve YSA tahmin değerleri.....	84

Şekil 4.9. Tüm tahminler için normalize edilmiş renk detaylı YSA performans verileri. ....	85
Şekil 4.10. Elde edilen renk detaysız 1 gizli katmanlı yapay sinir ağı modeli.....	86
Şekil 4.11. Birleştirilmiş veri için renk detaysız gözlem değerleri ve YSA tahmin değerleri.....	87
Şekil 4.12. İlk 200 test verisi için renk detaysız gözlem ve YSA tahmin değeri. ....	88
Şekil 4.13. DBR ürünü için renk detaysız kurulan YSA modeli.....	89
Şekil 4.14. DBR için renk detaysız gözlem ve YSA tahmin değerleri.....	90
Şekil 4.15. DBR ürünü ilk 200 veri için renk detaysız gözlem ve YSA tahmin değerleri.....	91
Şekil 4.16. Tüm tahminler için normalize edilmiş renk detaysız YSA performans verileri. ....	93
Şekil 4.17. DVM için tüm parametre kombinasyonları ve RMSE performansları. ..	94
Şekil 4.18. Birleştirilmiş veri için renk detaylı gözlem değerleri ve DVM tahmin değerleri.....	96
Şekil 4.19. İlk 200 test verisi için renk detaylı gözlem ve DVM tahmin değeri. ....	96
Şekil 4.20. DBR ürünü için renk detaylı gözlem ve DVM tahmin değerleri. ....	97
Şekil 4.21. DBR ürünü ilk 200 veri için renk deatylı gözlem ve DVM tahmin değerleri.....	98
Şekil 4.22. Tüm tahminler için normalize edilmiş renk detaylı DVM performans verileri. ....	99
Şekil 4.23. Birleştirilmiş veri için renk detaysız gözlem değerleri ve DVM tahmin değerleri.....	100
Şekil 4.24. İlk 200 test verisi için renk detaysız gözlem değerleri ve DVM tahmin değeri.....	101
Şekil 4.25. DBR için renk detaysız gözlem ve DVM tahmin değerleri. ....	102
Şekil 4.26. DBR ürünü ilk 200 veri için renk detaysız gözlem ve DVM tahmin değeri.....	103
Şekil 4.27. Tüm tahminler için normalize edilmiş renk detaysız DVM performans verileri. ....	105
Şekil 4.28. RO için tüm parametre kombinasyonları ve RMSE performansları. ....	106
Şekil 4.29. Birleştirilmiş veri için renk detaylı gözlem değerleri ve RO tahmin değeleri. ....	109
Şekil 4.30. İlk 200 test verisi için renk detaylı gözlem ve RO tahmin değeleri.....	110
Şekil 4.31. Birleştirilmiş veri için renk detaylı RO sonucunda değişkenlerin önem sırası, a) MSE'ye olan etki sıralaması, b) düğüm saflığı sıralaması. ....	111
Şekil 4.32. DBR ürünü için renk detaylı gözlem ve RO tahmin değerleri.....	112

Şekil 4.33. DBR ürünü ilk 200 veri için renk detaylı gözlem değerleri ve RO tahmin değerleri.....	113
Şekil 4.34. DBR için renk detaylı RO sonucunda elde edilen değişkenlerin önem sırası, a) MSE'ye olan etki sıralaması, b) düğüm saflığı sıralaması. ....	113
Şekil 4.35. Tüm tahminler için normalize edilmiş renk detaylı RO performans verileri. ....	115
Şekil 4.36. Birleştirilmiş veri için renk detaysız gözlem ve RO tahmin değeleri. ..	116
Şekil 4.37. İlk 200 test verisi için renk detaysız gözlem ve RO tahmin değeleri....	117
Şekil 4.38. Birleştirilmiş veri için renk detaysız RO sonucunda değişkenlerin önem sırası, a) MSE'ye olan etki sıralaması, b) düğüm saflığı sıralaması. ....	117
Şekil 4.39. DBR ürünü için renk detaysız gözlem ve RO tahmin değerleri.....	118
Şekil 4.40. DBR ürünü ilk 200 veri renk detaysız gözlem ve RO tahmin değeri. ..	119
Şekil 4.41. DBR için renk detaysız RO sonucunda elde edilen değişkenlerin önem sırası, a) MSE'ye olan etki sıralaması, b) düğüm saflığı sıralaması. ....	120
Şekil 4.42 Tüm tahminler için normalize edilmiş renk detaysız RO performans verileri. ....	122
Şekil 4.47. Yapay zeka yöntemleri için renk detaylı RMSE sonuçları. ....	124
Şekil 4.48. Yapay zeka yöntemleri için renk detaysız RMSE sonuçları. ....	124
Şekil 4.49. Yöntemlere göre karşılaştırmalı RMSE sonuçları. ....	125
Şekil 4.50. Yapay zeka yöntemleri için renk detaylı $R^2$ sonuçları. ....	128
Şekil 4.51. Yapay zeka yöntemleri için renk detaysız $R^2$ sonuçları. ....	128
Şekil 4.52. Yöntemlere göre karşılaştırmalı $R^2$ sonuçları. ....	129



## ÇİZELGELER DİZİNİ

### Sayfa

Çizelge 2.1. Dünya hazır giyim ihracatı(Bin \$).....	8
Çizelge 2.2. Türkiye tekstil ve hazır giyim ihracatı 1990-2009(Milyon \$).....	11
Çizelge 2.3. Türkiye hazır giyim ihracatı 2010-2017(Milyar \$) .....	12
Çizelge 2.4. Türkiye hazır giyim ithalatı(Bin \$) .....	13
Çizelge 4.1. Çalışmada kullanılan verilerin 2011 yılı 1. haftaya ait bölümü. ....	72
Çizelge 4.2. YSA için denenen bazı ağ kombinasyonları ve performansları. ....	78
Çizelge 4.3. Birleştirilmiş veri seti için renk detaylı YSA performansı. ....	81
Çizelge 4.4. DBR ürünü renk detaylı veri seti için YSA performansı. ....	82
Çizelge 4.5. Tüm ürünler için renk detaylı YSA performansları. ....	84
Çizelge 4.6. Tüm veri seti için renk detaysız YSA performansı. ....	88
Çizelge 4.7. DBR ürünü renk detaysız veri seti için YSA performansı. ....	90
Çizelge 4.8. Tüm ürünler için renk detaysız YSA performansları. ....	92
Çizelge 4.9. DVM için tüm parametreler ve performansları. ....	94
Çizelge 4.10. Birleştirilmiş veri seti için renk detaylı DVM performansı. ....	95
Çizelge 4.11. DBR ürünü renk detaylı veri seti için DVM performansı.....	97
Çizelge 4.12. Tüm ürünler için renk detaylı DVM performansları.....	98
Çizelge 4.13. Tüm veri seti için renk detaysız DVM performansı. ....	100
Çizelge 4.14. DBR ürünü renk detaysız veri seti için DVM performansı. ....	102
Çizelge 4.15. Tüm ürünler için renk detaysız DVM performansları. ....	103
Çizelge 4.16. 2 ile 26 değişken için RO performansı. ....	107
Çizelge 4.17. 10 ile 30 düğüm sayısı için RO performansı. ....	107
Çizelge 4.18. Çeşitli ağaç sayıları için RO performansı. ....	108
Çizelge 4.19. Tüm veri seti için renk detaylı RO performansı. ....	109
Çizelge 4.20. DBR ürünü renk detaylı veri seti için RO performansı. ....	112
Çizelge 4.21. Tüm ürünler için renk detaylı RO performansları. ....	114
Çizelge 4.22. Birleştirilmiş veri seti için renk detaysız RO performansı.....	115
Çizelge 4.23. DBR ürünü renk detaysız veri seti için RO performansı. ....	119
Çizelge 4.24. Tüm ürünler için renk detaysız RO performansları. ....	120

**Sayfa**

Çizelge 4.28. Tüm veri setleri ve yöntemler için RMSE performansları.....	123
Çizelge 4.29. Her bir yöntem için en düşük RMSE veren veri seti sayısı. ....	126
Çizelge 4.30. Yapay zeka yöntemlerinin veri setine göre karşılaştırmalı RMSE değerleri. ....	126
Çizelge 4.31. Tüm veri setleri ve yöntemler için R2 performansları.....	127
Çizelge 4.32. Her bir yöntem için en yüksek R2 veren veri seti sayısı.....	130
Çizelge 4.33. Yapay zeka yöntemlerinin veri setine göre karşılaştırmalı R2 performans değerleri. ....	130

## SİMGELER VE KISALTMALAR DİZİNİ

### KISALTMALAR

AB	: Avrupa Birliđi
ABD	: Amerika Birleşik Devletleri
ADALINE	: Adaptive Linear Neuron (Adaptif Doğrusal Nöron)
ARIMA	: Autoregressive Integrated Moving Average (Oto regresif Birleşik Hareketli Ortalama)
ARMA	: Autoregressive Moving Average (Oto regresif Hareketli Ortalama)
ATC	: Agreement on Textile and Clothing (Tekstil ve Giyim Anlaşması)
CART	: Classification And Regression Trees (Sınıflandırma ve Regresyon Ağaçları)
DTÖ	: Dünya Ticaret Örgütü
DVM	: Destek Vektör Makineleri
LVQ	: Learning Vector Quantization
MADALINE	: Multilayer Adaptive Linear Neuron (Çoklu Adaptif Doğrusal Nöron)
MAE	: Mean Absolute Error (Ortalama Mutlak Hata)
MSE	: Mean Square Error (Ortalama Hata Karesi)
NOS	: Never Out Of Stock (Asla Tükenmeyen)
OOB	: Out Of Bag (Çanta Dışı)
PBNN	: Probabilistic Basis Neural Network (Olasılık Temelli Yapay Sinir)
RBNN	: Radial Basis Functions Neural Networks (Radyal Temelli Yapay Sinir)
RMSE	: Root Mean Square Error (Hata Kareleri Ortalamasının Karekökü)
RO	: Rastgele Ormanlar
SARIMA	: Seasonal Autoregressive Integrated Moving Average (Sezonsal Oto regresif Birleşik Hareketli Ortalama)
SGK	: Sosyal Güvenlik Kurumu

TOBB : Türk Odalar ve Borsalar Birliđi  
TÜİK : Türkiye İstatistik Kurumu  
XOR : Exclusive OR (Özel Veya-Farklılık Operatörü)  
YSA : Yapay Sinir Ağları

## BÖLÜM 1

### GİRİŞ

Firmaların günümüzde gelinen noktada varlıklarını sürdürebilmeleri geleceği tahmin etme becerilerine bağlıdır. Değişen müşteri ihtiyaçları ve trendleri ise tahmin etme işlemini kolaylaştırmamaktadır. Firmaların karlılıklarını sürdürebilmeleri için müşteri ihtiyaçlarını tahmin etmeye ve bu tahminler neticesinde kısa, orta ve uzun vadeli planlarını oluşturarak hayata geçirmeye ihtiyaçları vardır. Çünkü planlamanın temelinde tahmin vardır. Bir sonraki satış sezonu için üretilecek ürün miktarını ve modelini doğru tahmin edebilmek ve buna uygun üretim yapmak ciddi bir yatırımdır. Eğer bu tahmin yanlış yapılırsa satışların düşmesine, itibar ve gelir kaybına neden olabilir. Bu nedenle talep tahmini firmaların kısa dönem hedeflerine ulaşmada en önemli girdilerden biridir. Üstelik talebi etkileyen birçok değişken sektöre göre farklılaştığı ve arz edicinin dışında şekillendiği için müdahale edilmesi pek mümkün olmayabilir. Firmaların hizmet ettiği marketin çeşitliliği ve müşteri davranışlarının farklılığı göz önüne alındığında birçok talep tahmini yöntemi geliştirilmiştir.

Gelecek dönem projeksiyonun doğru yapılamaması geçmiş dönem verilerinin doğru analiz edilememesi ile doğrudan ilişkilidir. Verilerin efektif kullanımı doğru bir projeksiyona dolayısı ile doğru sonuçlara öncülük etmektedir. Bazı durumlarda ise geçmiş dönem verileri yeterli olmadığı için yapılan tahminlerin hata oranları yüksek çıkabilmekte ya da tahmin yapılamamaktadır. Talep tahmini çalışmalarında, tahmini etkileyen faktörlerin belirlenmesi de tahmin işlemini zorlaştıran bir diğer faktördür. Klasik yöntemlerin kullanımı için verilerin eksiksiz olması gerekirken günümüzde yapay zeka sistemlerinin kullanımı sırasında eksik verilerin de doldurulması ve veri bütünlüğünün sağlanması mümkündür. Verilerin büyüklüğü de göz önüne alındığında yapay zeka sistemlerinin veriyi işlemesi ve örüntüler oluşturması klasik yöntemlere göre daha makul bir durumdur. Ayrıca klasik yöntemler doğası gereği

istatistiksel doğrulama (hipotez) işlemine ihtiyaç duyarken bu durum yapay zeka teknikleri için geçerli değildir.

Temelde talep tahmini yöntemleri nitel ve nicel yöntemler olmak üzere iki alanda sınıflandırılmaktadır. Nitel veriler kişiler yargıları ve uzman görüşlerini kullanırken nicel veriler ise matematiksel ve istatistiksel veriler kullanılmaktadır. Yapılan tahminin doğruluğu ve güvenilirliği ise başka bir değerlendirme konusudur. Teknolojik gelişmelere paralel olarak gelişen yapay zeka teknolojisi ile birlikte yapılan tahminlerin doğruluğu ve güvenilirliği oldukça artmıştır.

Bu tez kapsamında perakende hazır giyim endüstrisindeki ürün çeşitliliğini dikkate alarak yapay zeka yöntemleri kullanarak minimum hata oranı ile satış talep tahmini yapılmıştır. Türkiye'nin en büyük perakende hazır giyim firmasının “kadın never-out-of-stock” ile “erkek never-out-of-stock” ekiplerinin yaz ve kış sezonunda satışını yaptığı örme, triko, dokuma ve denim ürünlerin talep tahmini çalışma kapsamı içerisinde değerlendirilmiştir. Klasik yöntemlerin dikkate alamadığı birçok değişkeni yapay zeka teknikleri ile modele dahil ederek tahminin doğruluğunu arttırmak çalışmanın birincil hedeflerindedir. Bu bağlamda yapay zeka modellerinden yapay sinir ağları (YSA, Artificial Neural Network-ANN), destek vektör makinaları (DVM, Support Vector Machines-SVM) ve rastgele ormanlar (RO, Random Forests-RF) modelleri kurularak veri setinden çıkarımlar yapılmış ve klasik yöntemler ile de karşılaştırılmıştır. Giyim endüstrisinde sık görülen satışa çıkan ürünlerin renklerinin belirli bir kısmının diğer renklerden önce bitmesi durumunda satışın tek bir renge yoğunlaşması, diğer renklerin satış görememesi gibi tahmini olumsuz etkileyebilecek durumların değerlendirilmesi için ürünlerin renk detayları çalışma kapsamına alınmıştır. Ayrıca ülkenin ekonomik ve siyasal konjonktürü, hava durumu, özel günler vb. gibi talebi etkileyen faktörleri de göz önüne alarak yüksek doğrulukta bir tahmin yapılmıştır.

Çalışmanın ikinci bölümünde hazır giyim endüstrisinin tarihi, Türkiye ekonomisindeki yeri ve sektörün zorluklarından bahsedilmiştir. Ayrıca bu bölümde literatürde yapılmış diğer tahmin çalışmaları incelenmiş ve sonuçları paylaşılmıştır. Talep tahmininin hazır giyim endüstrisi için önemi ve tahmin işleminin yapılması

aşamasında karşılaşılabilecek zorluklarda yine bu bölümde irdelenmiştir. Üçüncü bölümde talep tahmin yöntemleri incelenmiş ve dördüncü bölümde ise yapay zeka yöntemlerinden bahsedilmiştir. Uygulama bölümünde ise tahmin çalışması yapılacak ürünler için renk detayının yer aldığı ve renk detayının yer almadığı iki farklı veri seti ile yapay sinir ağları, destek vektör makinaları ve rastgele ormanlar yöntemleri kullanılarak tahmin çalışması yapılmıştır. Renk detayının eklenmesinin modellerin performansı üzerindeki etkisi, modellerin başarısı ve gelecek çalışmalar için yapılan yorumlar ise sonuçlar bölümünde tartışılmıştır.

## BÖLÜM 2

### HAZIR GIYİM ENDÜSTRİSİ

Bugün moda olarak karşımıza çıkan ve insanların çeşitli sebeplerle örtünmek için kullandığı birtakım araçlar hazır giyim endüstrisini oluşturmaktadır. Sosyal itibar, kültür, ekonomi, teknoloji gibi etkenler terzilik olarak başlayan tekstil endüstrisini seri üretim ve hazır giyime doğru itmiştir [1].

Giyim endüstrisinin gelişmesi ve kültürlerdeki öneminin artması ile moda konseptinin yaygınlaşması giyim sanayisinin gelişmesine oldukça fazla katkı sağlamıştır. Tekstil ve hazır giyim endüstrisini oluşturan süreçler pamuk aşamasından başlayarak elyaf ve iplik üretimine ve sonrasında da giyim eşyasına dönüşmeyi kapsar. Buna göre tüm üretim süreçleri pamuğun işlenmesi, iplik üretimi, dokuma, örgü işlemi, boyama, baskı, pul-payet işleme, kumaşın kesilmesi ve dikilmesinden oluşmaktadır. Pamuktan kumaş üretimine kadar olan kısım tekstil, kumaş kesiminden giyim eşyasının elde edilmesine kadar olan kısım ise hazır giyim olarak sınıflandırılmaktadır [2]. Hazır giyim belirli kalıplar ve ölçüler kullanılarak elde edilen giyim eşyalarının tamamı olarak tanımlanmaktadır. [1]

Hazır giyim ve tekstil endüstrisi ülke ekonomisinin kalkınmasında önemli bir role sahiptir ve yarattığı istihdam ile kalkınmanın önemli bir destekçisidir. Emek yoğun bir sektör olan hazır giyim ve tekstil endüstrisi bu yapısı nedeni ile gelişmekte olan ülkelerin yatırım yaptığı bir sektördür. Sanayi devrimi sonrası birçok sanayileşmiş ülkenin kalkınmasında lokomotif görevi gören bu endüstri, ekonomik kalkınmanın ileri aşamalarında olan ülkelere üretim içerisindeki payını kaybetmiştir. Hazır giyim markaları Amerika ve Avrupa ülkelerinde kümelenmiş olsa da bu markaların üretimi gelişmekte olan ülkelere kaymıştır. Bunun en büyük nedeni ise hammadde ve işgücü maliyetlerinin diğer ülkelere göre düşük olmasıdır. Diğer yandan İtalya örneğinde olduğu gibi, gelişmiş ülkeler de koleksiyon anlamında yaptıkları çalışmalar ile



birlikte teknolojik imkanları da kullanarak, geliřmekte olan ÷lkelerle üretim anlamında rekabet edemese bile, belirli bir üretim kapasitesini korumaktadır [1–3].

## **2.1. DÜNYADA HAZIR GİYİM VE TEKSTİL**

Tekstil ya da hazır giyim endüstrisi ihracata yaptığı katkı nedeniyle ÷lkelerin gelirleri açısından değerlendirildiğinde ÷lke ekonomilerinde lokomotif görevi görmektedir. Özellikle geliřmekte olan ÷lkelerde emek yoğun bir sektör olarak ÷lke ekonomisine önemli katkı sağlamaktadır.

Temel ihtiyaçlardan biri olan hazır giyim sektörü, dünya çapında rekabetin yaşandığı ve sürekli olarak arttığı sektörlerden biridir. Değişen sosyal koşulların etkisi, teknolojik geliřmeler, diğer ÷lkelerin daha ulaşılabilir olması bu rekabeti arttırmaktadır. İnternet ile birlikte markaların diğer ÷lkelerdeki tüketicilere kolayca ulaşabilmeleri yerel markalar için yeni bir cephe açmış ve tüm dünya tek bir pazar haline gelmiştir.

Şu an da ekonomik olarak gelişimini tamamlamış İngiltere, Kuzey Amerika, Japonya gibi ÷lkelerin gelişim döneminde önemli bir rol oynayan hazır giyim endüstrisi 1970’li yıllardan sonra üretim ve ihracat anlamında geliřmekte olan ÷lkelere kaymıştır. Örnek olarak Japonya’da istihdam sorunu ve üretim maliyetlerindeki artış üretimin diğer Asya ÷lkelerine kaymasına neden olmuştur. Japonya’nın tetiklediği bu süreçte Hong Kong, Güney Kore ve Tayvan gibi ÷lkeler tekstil ihracatçısı konumuna gelmiş ve Asya’da yeni sanayileşen ÷lkeler olarak ortaya çıkmıştır. Bu ÷lkelerin yanı sıra Bangladeş ve Endonezya gibi yüksek nüfusa ve düşük maliyetli iş gücüne sahip olan ÷lkeler bu avantajlarını bir rekabet silahına dönüştürmüşlerdir [4].

Sonrasında benimsenen küreselleşme eğilimi ile birlikte sektör hızlı bir büyüme eğilime girmiş ve günümüzde bakıldığında küreselleşen sektörlerden biri olmuştur. Bununla birlikte sektörün kapasitesinin yarısından fazlası geliřmekte olan ÷lkeler tarafından sahiplenilmiştir [2].

Tüm bu kapasite deęişimleri dikkate alındığında gelişmiş olan ülkelerin geliřmekte olan ülkelere karşı kendilerini korumak adına birtakım girişimleri olmuřtur. Bu girişimler nihayetinde kısıtlayıcı tedbirler olarak karşımıza çıkmıştır. İlk bařlarda geçici olarak yürürlüğe giren tedbirlerin birincisi 1961 yılında yürürlüğe girmiştir. İlk kez “Uluslararası Pamuklu Tekstil Ticaretine İliřkin Kısa Dönemli Düzenleme” olarak yürürlüğe giren bu anlaşma 1973 yılına kadar uzatılarak “Uzun Dönemli Pamuklu Tekstil Düzenlemesi” olarak isimlendirilmiştir. Sadece pamuklu ürünleri kapsam içine alan bu anlaşmayı 1974 yılında yürürlüğe giren “Çoklu Elyaf Anlaşması” takip etmiş ve tekstil ticaretinin genel ithalat kotaları tanımlanmıştır. Daha sonrasında anlaşmaya ipek ve dięer bitki kökenli elyaflarında da dahil edilmesi ile anlaşma 1986 yılında tekrar uzatılmıştır. 1 Ocak 1995 yılında ise Dünya Ticaret Örgütü (DTÖ) Anlaşması dahilinde Tekstil ve Giyim Anlaşması (Agreement on Textile and Clothing – ATC) imzalanmış ve çoklu elyaf anlaşması kapsam dıřı kalmıştır. Tekstil ve Giyim Anlaşmasına göre gelişmiş olan ülkeler tekstil ve hazır giyim ürünler için uygulanan kotaları kademeli olarak 10 yıl içerisinde sonlandırmayı ve sonrasında ticareti Dünya Ticaret Örgütü Anlaşmasının sınırları içerisinde yürütmeyi taahhüt etmişlerdir [3–5].

Uzun bir süre ara verilen uluslararası tekstil rekabeti 2005 yılında tüm kısıtlamaların kalkmasıyla yeni bir çaęa girmiştir. Bu süreç içerisinde sektördeki dengeler ve kořullar deęişmiş, üretim kapasiteleri yer deęiřtirmiştir. Asıl rekabetin bařladığı bu dönemde kapasitelerin yer deęiřtirmesi Çin’in yıldızının parlamasına neden olmuřtur. 11 Aralık 2001’de Dünya Ticaret Örgütüne katılımı sayesinde Çin, Avrupa Birlięi (AB) ülkeleri ile etkileřimini arttırmıştır ve bu olay dünya tekstil ve hazır giyim endüstrisini kökünden deęiřtirmiştir. Bu süreçte Çin’in tekstil ve hazır giyim sektöründeki ithalatı miktar bazında %35,6 ve deęer bazında ise %10,5’lik bir rekor artış göstermiştir. Çin’in en büyük avantajı kalabalık nüfusunun getirdięi ucuz işgücü gibi görünse de Çin hükümetinin Çin’i tekstil sektöründe dünyada öncü bir konuma getirmek için uyguladığı agresif politika da oldukça etkilidir. Bu politika çerçevesinde Çin hükümeti Çinli üreticilere sermaye desteęi, direkt ve dolaylı yollardan sübvansiyonlar ve bazı teřvikler sağlamaktadır. Ayrıca Çin’in en büyük pamuk ve polyester üreticilerinden biri olması da sektördeki avantajını arttırmaktadır [2,3].

Günümüzde Dünya Ticaret Örgütü'nün rakamlarına göre Çin en büyük tekstil ve hazır giyim üreticisi ve ihracatçısıdır. Dünya Ticaret Örgütü 2016 yılında yayınlanan verilerine göre 2014 yılı itibari ile Çin tekstil ve hazır giyim ürünlerinin ticaretindeki payını bir önceki yıla göre %5 arttırmış ve 298 milyar dolara ulaşmıştır. Bu hacim ile birlikte dünya tekstil ve hazır giyim ihracatındaki payını ise %37,4'e yükseltmiştir. AB ise 200 milyar dolarlık ihracatı ile 2. Sırada yer almıştır ama bu ticaretin büyük bir çoğunluğu Avrupa Birliği üyesi ülkeler arasında gerçekleşmiştir. Bu ülkelerden en çok dikkat çekenleri ise İtalya, İngiltere, Almanya, Fransa ve İspanya'dır. Avrupa Birliği'nin 2. büyük tekstil ihracatçısı olmasına karşın sektördeki payı ise her geçen gün azalmaktadır. Buna karşın teknolojik üstünlüklerini iyi yönetmeyi başaran İtalya, İspanya gibi bazı Avrupa Birliği üyesi ülkeler yüksek katma değer gerektiren, moda yön veren ürünler üreterek tekstil ve hazır giyim endüstrisindeki konumlarını korumaya çalışmaktadırlar [4,6].

Hazır giyim tekstilden ayrı düşünüldüğünde gelişmeler farklı bir yönelim içerisine girmiştir. Çin en büyük ihracatçı konumundadır. Buna karşın Amerika Birleşik Devletleri (ABD) ile serbest ticaret anlaşmasına sahip Meksika ve Avrupa Birliği ile gümrük anlaşmasına sahip Türkiye bu alanda paylarını yükseltmektedir. Elbette bu noktada düşük maliyet ve tekstil endüstrisinde "fast track" olarak isimlendirilen taleplere cevap verebilme yeteneği de bu iki ülke için ayırt edici özellik olmuştur. Fast track kavramı ile birlikte hazır giyim pazarının eğilimi bir aydan daha kısa sürede termin içeren, modayı yakından takip eden, arzu edilen kaliteyi sağlayan ve düşük maliyete sahip olan ülkelere yönelmiştir. Amerika bu eğilim sonrası üretimlerini Meksika'ya kaydırmış, bu durum Tayvan, Güney Kore, Tayvan gibi ülkelerin üretiminin azalmasına neden olmuştur. Avrupa Birliği ise birlik içerisindeki üretimi AB üyesi olmayan Avrupa ülkelerine ya da Türkiye, Mısır, Fas gibi Orta ve Doğu Avrupa, Kuzey Afrika ve Orta Doğu ülkelerine kaydırmışlardır [4]. Bu durum ayrıca AB'yi en büyük alıcı pozisyonuna getirmektedir [2].

2008 yılında ABD'de başlayan ve tüm dünyayı etkileyen kriz nihayetinde tüketici satın alma alışkanlıklarını etkilemiş ve global çapta talepte bir düşüş yaşanmasına neden olmuştur. 2013 ve sonrasında toparlanma trendine giren dünya ekonomisi ile birlikte hazır giyim ve tekstil ticareti de hız arttırmıştır.

Çizelge 2.1’deki verilere göre dünya tekstil ve hazır giyim ticaret hacmi 2016 yılında 434,9 milyar dolar olarak gerçekleşmiştir. Türkiye ise 14,7 milyar dolar ile %3,4’lük bir paya sahip olmuştur. Dünya nüfusunun artması ve modanın insan hayatındaki öneminin artması ile itibar simgesi haline gelmesi tekstil ve hazır giyim tüketiminin artmasına neden olmuştur.

Çizelge 2.1. Dünya hazır giyim ihracatı (Bin \$) [2].

Ülkeler	2016
<b>Dünya</b>	<b>434 981 632</b>
<b>Çin</b>	146 478 365
<b>Bangladeş</b>	32 551 632
<b>Vietnam</b>	24 812 943
<b>İtalya</b>	19 968 409
<b>Almanya</b>	17 116 335
<b>Hindistan</b>	16 961 165
<b>Hong Kong</b>	14 915 743
<b>Türkiye</b>	14 774 754
<b>İspanya</b>	12 283 113
<b>Fransa</b>	10 012 030
<b>Belçika</b>	8 404 263
<b>Birleşik Krallık</b>	7 905 650
<b>Hollanda</b>	7 867 254
<b>Endonezya</b>	7 171 030
<b>Kamboçya</b>	6 627 199
<b>ABD</b>	4 949 606
<b>Polonya</b>	4 839 131
<b>Pakistan</b>	4 600 492
<b>Sri Lanka</b>	4 598 051
<b>Meksika</b>	4 061 754

## 2.2. TÜRKİYE’DE HAZIR GIYIM VE TEKSTİL

Tekstil gibi emek yoğun sektörler genç Türkiye’nin temel endüstrilerinden biridir. Dünya’da yaşanan ekonomik ve sanayi alanındaki değişim ile birlikte temel bir ihtiyaç olan giyim endüstrisi gelişmiş ülkelere kayarken Türkiye’de bu değişimden etkilenmiştir. Dünyadaki sanayileşme trendi ticarete ivmelenmeyi tetiklemiş ve bu ivme ile birlikte tekstil sektörü hızlı bir yükseliş yaşamıştır. Dünya ile paralel olarak Türkiye’de de hazır giyim ve tekstil en fazla sanayileşen ve gelişen sektör olmuştur. Bu değişim en doğal getirisi olarak istihdam potansiyeli ve ihracat geliri ortaya çıkmıştır. 1980’li yıllarda başlayan bu gelişim

2000 yılına gelindiğinde zirveye ulaşmış ve tekstil ve hazır giyim endüstrisi yıllık %20,5 büyüme oranını yakalayarak Türkiye'nin en büyük ihracat sanayisi konumuna gelmiştir [7].

2001 yılında Çin, Dünya Ticaret Örgütüne katılması ile hazır giyim ve tekstil endüstrisinde lokomotif olmaya başlamış ve bu durumda Türkiye'nin hazır giyim ve tekstil sektöründeki ihracat oranları gerilemeye başlamıştır. Buna rağmen hazır giyim ve tekstil endüstrisi Türkiye'nin tarım sonrasında en büyük istihdam yaratan sektörü olmayı başarmıştır. Cumhuriyet sonrasındaki dönemde tekstil endüstrisi ülke kalkınması için önemli bir rol oynamıştır ve ilk kalkınma planında yer almıştır. Devlet bu noktada tekstil endüstrisine doğrudan destek vermiş ve kamu kurumları aracılığı ile yatırımlar yapmıştır. Bu yatırımlar tarımsal arz ile bağlantılı olduğundan pamuk üretimi de bu dönemde desteklenmiştir. Ayrıca üretim noktasında olduğu kadar tüketim noktasında da bu desteğini sürdürmüştür. Sümerbank'ın kurulması ile birlikte devlete ait tüm tekstil ve hazır giyim üretimi bu oluşumun kapsamına girmiştir. 1937 yılına kadar Kayseri, Ereğli, Malatya ve Nazilli'de iplik fabrikaları bu süreçte kurulmuş ve 1950'li yıllardan sonra atölye tarzındaki özel yatırımlar hizmete başlamıştır. 1960 ve sonrasında yoğunlaşılacak sanayileşme trendi ile birlikte günümüz tekstil ve hazır giyim endüstrisinin temelleri Türkiye'de atılmaya başlanmış 1980 ve sonrasında ise ivmesini kaybetmeyen tekstil ve hazır giyim endüstrisi bir numaralı ihracat kalemi olmuş ve getirdiği döviz kazancı ile ekonomik büyümeyi güçlendirmiştir. 1990'lı yıllarda ise tekstil ve hazır giyim endüstrisi ortalamanın oldukça üzerinde bir büyüme eğrisi yakalamıştır. Tüm dünyada ve Avrupa'da tekstil ve hazır giyim ürünlerine uygulanan kotalara rağmen düşük işgücü maliyetleri, kaliteli ürün, düşük taşıma maliyetleri, kısa süreli terminler ve Türk firmalarının sağladığı diğer avantajlar ile birlikte Türkiye, Avrupa'nın en büyük ithalat kaynağı konumuna gelmiştir. Sadece ham pamuk ihracatı yapan Türkiye kısa bir süre içerisinde Avrupa'nın en büyük tekstil ve hazır giyim ihracatçısı olmuştur. Türkiye 1996 yılında Avrupa ile Gümrük Birliği Anlaşması'nı tamamlamış ve Avrupa Birliği uygulamalarıyla uyum sağlamıştır. Oluşan bu olumlu hava 1997 yılında Avrupa Birliği'nin aday ülkelerindeki ithalat vergilerini ve kotalarını sıfırlaması sonucu tersine dönmüş ve bu etkileşim 1997 yılında ilk kez Türk tekstil ve hazır giyim ihracat rakamlarının düşmesine neden olmuştur. Bu düşüşte etkili olan bir diğer

etken ise Gümrük Birliği'nin getirdiği olumlu havaya kapılan Türk tekstil ve hazır giyim endüstrisinin plansız yaptığı kapasite yatırımlarının Dolar karşısında artan Euro sonucu Avrupa Birliği'nin yaşadığı durgunluk nedeniyle atıl kalmasıdır [4,7].

1990 yılında 12,9 milyar dolar olan Türkiye'nin toplam ihracatı içerisinde tekstil ve hazır giyim endüstrisinin payı %36,81 olarak gerçekleşmiştir. Bu rakam 2000 yılında 27,7 milyar dolara yükselmiş fakat tekstil ve hazır giyim endüstrisi payı değişmeyerek %36,74 olarak gerçekleşmiştir. 2008 yılında ise Türkiye'nin toplam ihracatı 107,2 milyar dolara yükselmiştir. Fakat tekstil ve hazır giyim endüstrisinin payı 2001 yılında yaşanan büyük krizin de etkisi ile birlikte düşmüş ve %17,41 olarak gerçekleşmiştir. 2009 yılında ise ABD'de başlayan ve tüm dünyayı etkileyen küresel kriz nedeni ile Türkiye'nin toplam ihracatı 102,1 milyar dolar gerçekleşerek bir önceki yıla göre gerilemiş, tekstil ve hazır giyim sektörü bu gerileme sürecinde miktarsal olarak 3,7 milyar dolar azalmış yüzdesel olarak ise artarak %18,87'lik paya sahip olmuştur. Tekstil ve hazır giyim endüstrisi 1990 yılında 4,7 milyar dolarlık bir hacme sahipken 2009 yılında yaklaşık beş kat artarak 19,2 milyar dolara yükselmiştir. Türkiye'nin en büyük ihracat kalemi hazır giyim endüstrisi ise bahsi geçen dönemde yaklaşık olarak dört kat artmış ve 3,3 milyar dolardan 11,5 milyar dolara yükselmiştir [7].

Türkiye'nin tekstil ve hazır giyim endüstrisinde en fazla ihracat gerçekleştirdiği ülkeler Almanya, İngiltere, İspanya, Fransa ve Hollanda olmuştur. Bu ülkelere yapılan ihracat 2007 yılında tekstilde 1 milyar 460,4 milyon dolar olarak gerçekleşirken hazır giyimde 8 milyar 367,6 milyon olmuştur ve toplamda 9 milyar 828 milyon olarak gerçekleşmiştir (Çizelge 2.2) [7]. 2016 yılında ise hazır giyim için bu ülkelere olan ihracat hacmi 7 milyar 649,5 milyondur [2]. Türkiye tekstil ve hazır giyim ihracatında 2015 yılı itibariyle %3,5 paya sahiptir ve bu pay ile dünya sıralamasında 7'nci sıradadır.

2016 yılı ve sonrasında Türkiye'nin hazır giyim endüstrisinin ihracat yaptığı ülkeler arasında Almanya %18,19'luk pay ile birinci sıradadır. Fakat 2001 ve 2016 yılları arasındaki ihracat rakamları incelendiğinde İspanya Inditex grubunun etkisiyle, Doğu Avrupa, Rusya, Kuzey Afrika ülkeleri ve Arap ülkeleri ise LC Waikiki etkisiyle

ihracat paylarını sürekli arttırırken Almanya, İngiltere ve Fransa gibi bazı Avrupa ülkelerinin ve ABD'nin payı sürekli olarak azalmıştır [2].

Çizelge 2.2. Türkiye tekstil ve hazır giyim ihracatı 1990-2009 (Milyon \$) [7].

Yıllar	Toplam İhracat (Milyon \$)	Tekstil (Milyon \$)	Hazır Giyim (Milyon \$)	Tekstil ve Hazır Giyim İhracatının Toplam İhracattaki Payı (%)
1990	12 959	1 440	3 330	36,81
1995	21 637	2 526	6 118	39,95
1996	23 224	2 722	6 067	37,84
1997	26 261	3 352	6 697	38,27
1998	26 974	3 548	7 057	39,32
1999	26 587	3 477	6 515	37,58
2000	27 775	3 672	6 533	36,74
2001	31 334	3 942	6 661	33,84
2002	36 059	4 244	8 056	34,11
2003	47 253	5 261	9 961	32,21
2004	63 167	6 428	11 193	27,9
2005	73 476	7 075	11 833	25,73
2006	85 535	7 584	12 051	18,88
2007	107 272	8 942	13 886	17,52
2008	132 002	9 399	13 590	17,41
2009	102 138	7 723	11 555	18,87

2008 yılında ABD'de başlayan küresel krizin etkisiyle Türkiye'nin ihracatı düşmüş fakat sonraki süreçte 2013 ve 2014 yıllarında %7,9'luk pay ile sektör toparlanma göstermiştir. 2015 ve sonrasında ise ihracat düşme trendine girmiş ve 2017 yılı itibari ile %6,4'lük oran ile 10,1 milyar dolar olarak gerçekleşmiştir (Çizelge 2.3) [8].

Çizelge 2.4'e göre Türkiye'nin 2016 yılında yaptığı toplam ithalat 2 milyar 483 milyon dolardır. Bu rakam Türkiye'yi hazır giyim endüstrisinde en çok ithalat yapan 27'nci ülke konumuna koymaktadır. Türkiye'nin 2016 yılı rakamları baz alındığında en çok ithalat yaptığı ilk beş ülke sırasıyla Çin, Bangladeş, İtalya, Mısır ve Vietnam olmuştur. Bu ülkeler arasında Çin %29,05'lik bir paya sahipken en az ithalat yapılan ülke olan Moldova'nın payı ise %0,56'dır. Listelenen ilk 20 ülke Türkiye'nin 2016

yılı itibari ile hazır giyim ithalatının %93,99'unu kapsamaktadır. Bu süre zarfında Çin, Bangladeş, Mısır, Vietnam gibi ülkeler ithalat paylarını arttırırken İtalya, İspanya Bulgaristan ve Almanya gibi ülkelerin ise ithalat payları azalmıştır [2].

Çizelge 2.3. Türkiye hazır giyim ihracatı 2010-2017(Milyar \$) [8].

Yıllar	Toplam İhracat (Milyar \$)	Tekstil (Milyar \$)	Tekstil İhracatının Toplam İhracattaki Payı (%)
2010	113,9	8,8	7,7
2011	134,9	10,6	7,9
2012	152,5	10,9	7,2
2013	151,8	12,0	7,9
2014	157,6	12,5	7,9
2015	143,8	11,0	7,6
2016	142,5	10,9	7,6
2017	157,0	10,1	6,4

Tekstil ve hazır giyim endüstrisi Türkiye'nin ihracat/ithalat dengesinde en yüksek orana sahip endüstrisidir. İstihdam ve toplum refahına da gayri safi yurtiçi hasılanın %10'undan fazlasını oluşturması nedeniyle oldukça fazla etki sağlamıştır [8,9].

Türkiye'de tekstil ve hazır giyim endüstrisinde faaliyet gösteren işletmeler genel yapıları itibariyle, atölye, küçük ve orta ölçekli işletmeler ve taşeronlar şeklindedir. Bu nedenle kesin olarak sektördeki çalışan sayısı belirlenememektedir. Türkiye İstatistik Kurumu (TÜİK) ve Türkiye Odalar ve Borsalar Birliği (TOBB) tarafından yayımlanan verilere göre tekstil ve hazır giyim endüstrisinde çalışan sayısı 2007 yılı itibariyle 800 000 kişidir. Kayıt dışı istihdam da dikkate alındığında 2 milyondan fazla kişinin tekstil ve hazır giyim endüstrisinde istihdam edildiği tahmin edilmektedir [4]. Sosyal Güvenlik Kurumu (SGK) 2016 verilerine göre ise 408 554 kişi tekstil imalat sanayinde istihdam altındadır [8].



Çizelge 2.4. Türkiye hazır giyim ithalatı (Bin \$) [2].

Ülkeler	2016
<b>Dünya</b>	<b>2 483 683</b>
<b>Çin</b>	721 408
<b>Bangladeş</b>	652 461
<b>İtalya</b>	132 938
<b>Mısır</b>	125 945
<b>Vietnam</b>	74 178
<b>Serbest Bölgeler</b>	74 116
<b>Hindistan</b>	73 604
<b>Kamboçya</b>	64 702
<b>İspanya</b>	64 209
<b>Gürcistan</b>	57 469
<b>Romanya</b>	52 633
<b>Pakistan</b>	33 266
<b>Portekiz</b>	32 157
<b>Sri Lanka</b>	31 771
<b>Endonezya</b>	31 060
<b>Bulgaristan</b>	29 898
<b>Romanya</b>	26 853
<b>Almanya</b>	24 541
<b>Malezya</b>	17 357
<b>Moldova</b>	13 812

### 2.3. HAZIR GİYİM SEKTÖRÜNDE TALEP TAHMİNİ

Talep tahmin çalışmaları birçok sektör için önemli bir çalışma alanıdır, fakat perakende sektörü bu konuda diğer sektörlerle göre daha zorlu bir sahadır. Bunun en önemli sebebi ise talebi etkileyecek olan değişkenlerin kesin olarak bilinmemesidir. Hazır giyim endüstrisi de satışların birçok değişken tarafından etkilendiği, mevsimsellik ve sezonsallığın yüksek olduğu bir alandır. Perakende sektörü genel olarak hızlı satış eğilimindedir. Bir müşteri mağaza içerisinde istediği ürünü istediği özelliklerde bulamaz ise rakip mağazaya girerek ihtiyacını gidermektedir. Bu da mağazalar için satış kaybı anlamına gelmektedir. Bu nedenle müşterinin ihtiyacını doğru tahmin etmek oldukça önemlidir.

Satış tahmini, üreticiye, üretim ve yenileme stratejisinin belirlenmesinde ve stok yönetiminde, iş gücü kullanımında ve planlanmasında yol göstermektedir.

### **2.3.1. Talep Tahminin Gerekliliği ve Önemi**

Tahmin üretimin başlangıç noktası olarak kabul edilebilir. Yapılan tahmine göre bütçelerin oluşturulması, üretim ya da satın alma planının oluşturulması, hammadde yatırımlarının yapılması, insan gücünün ayarlanması gerekmektedir.

Hazır giyim endüstrisinde talep tahminin doğru yapılması son derece önemlidir. Aksi takdirde sonraki adımlar da yanlış yönlendirileceği için kaynakların verimsiz kullanılmasına neden olacaktır. Hatalı tahmin yapılması hatanın yönüne göre fazla üretim yapılmasına ya da az üretim yapılmasına neden olabilir. Gerçekleşen talepten fazla üretim yapılması durumunda stok maliyetlerinde artış, sonraki yıllara stok devri ve modadan kopma dolayısı ile müşteri kaybı gerçekleşebilir.

Gerçekleşen talepten daha az üretim yapılması durumunda ise müşterilerin ürün bulamaması sonucu satış kaybı oluşması ve marka prestijinin olumsuz etkilenmesi söz konusudur. Bu durum ayrıca müşteri sadakatini ve müşterinin markaya olan inancını da olumsuz etkileyebilir [10].

### **2.3.2. Talep Tahminin Zorlukları**

Tahmin etmek, bilinmeyen bir geleceğin, bilinen geçmiş verilerin baz alınması ve analiz edilmesi sonucu şekillendirilmesidir. Fakat gelecek gerçekleşene kadar tahmin edilmiş verinin doğruluğu bilinmemektedir. Tahmin edilen veri ile gerçekleşen veri arasında bir fark olması beklenmektedir. Talep tahmininin en büyük zorluğu bu tahmin hatasını sifıra indirmektir. Tahmin edilen veri ile gerçekleşen veri arasındaki hata ne kadar az olursa tahmin doğruluğu o kadar artar.

Tahminin doğruluğunu etkileyen faktörler ise tahmin modellerinde kullanılan girdi değişkenleridir. Girdi değişkenlerinin talebi doğru açıklayabilmesi beklenmektedir fakat değişkenlerin belirlenmesi hazır giyim endüstrisi için hiç de kolay değildir. Bir modelin satışını etkileyebilecek değişkenler ürünün rengi, hava durumu, rakip mağazadaki modeller, mevsim, satın alma gücü, ülkenin ekonomik konjonktürü

şeklinde sıralanabilir. Elbette ki bu parametreler detaylı analizler sonrası çoğaltılabilir.

Tahmin çalışmasına başlamadan önce kullanılacak veri setinin hazırlanması ve belirlenen girdi parametrelerinin talep ile olan ilişkisi istatistiksel yöntemlerin yardımı ile incelenebilir.

Veri setinin hazırlanması ise talep tahmini çalışmalarının bir diğer zorluğudur. Çoğu firma geçmiş satış verilerini bir şekilde sistemlerinde tutsalar bile bu veriler çoğu zaman düzenlenmemiş, ham şekilde tutulmaktadır. Talep tahmini çalışması yapılabilmesi için bu verilerin temizlenmesi ve düzenlenmesi gerekmektedir. Ayrıca fazla bir veriye sahip olmayan ürünlerin tahmin duyarlılıkları fazladır.

Tahmin yöntemlerinde kullanılan matematiksel modellerin tamamı, tahminde kullanılan girdi verilerinin sayısal veriler olması gerekliliğini ortaya koyar. Klasik yöntemlerin tamamı bu yönde geliştirilmiş ve sayısal veriler aracılığı ile çalışmaktadır. Fakat hazır giyim endüstrisinde ürüne olan tahmini etkileyen renk, beden gibi bazı faktörler sayısal olarak ifade edilemeyebilir. Bu faktörlerin modellere dahil edilmesi için çeşitli veri dönüştürme yöntemleri geliştirilmiştir.

## **2.4. LİTERATÜR TARAMASI**

Talep tahmin çalışmaları geçmişten günümüze birçok alanda kullanılmaya devam etmektedir ve literatürde sayısız uygulamaya sahiptir. Zaman serileri gibi klasik yöntemlerin yanı sıra gelişen teknoloji ile birlikte uygulama alanlarını arttıran yapay zeka tabanlı yöntemlerde talep tahmini çalışmalarında sıklıkla kullanılmaktadır. Ayrıca literatürde yer alan birçok çalışmada araştırmacılar tarafından yeni yaklaşımlar önerilmiş ya da var olan yöntemler aynı verilere uygulanarak karşılaştırılmışlardır.

Zhou vd.'nin 2000 yılında yaptıkları çalışmalarında eğilim, sezonsallık, iklim korelasyonu ve otokorelasyon gibi faktörlerin su kullanımı üzerine olan etkilerini de dikkate alarak zaman serileri ile talep tahmini yapmışlardır. Avustralya'nın

Melbourne şehrine ait iki aylık yaz dönemi su kullanım verilerini kullandıkları çalışmalarında kurdukları tahmin modeli %89,6 yeterlilikle ve %8 standart hata oranı ile başarılı olarak tahmin işlemini gerçekleştirmiştir [11]. Bir diğer çalışmada Zhai vd. 2012 yılında Pekin'e ait su talebini tahmin etmek için zaman serisi modelleri kullanmışlardır [12].

Whiting vd. 2000 yılında karides tüketime ilişkin kısa dönemli bir tahmin çalışması yapmışlardır. Çalışmalarında kurdukları modele suyun tuzluluğu, sıcaklık, dönem ve bulanıklık gibi karides yetiştiriciliğinde önemli olan ve sektörde bilinen faktörlerin yanı sıra stokların durumu, karides yetiştirilen havuzun karakteristiği gibi faktörleri de dikkate alan bir Bayes tahmin modeli kurmuşlardır. Temelde yaptıkları çalışmada basit regresyon modeli kullanan araştırmacılar bu modeli ampirik Bayes tahmin modeli ile hibritlemişlerdir [13].

Rajopadhye vd. 2001 yılında Holt-Winters yöntemini kullanarak hotel endüstrilerinde kesin olmayan talebi tahmin etmek için çalışma yapmışlardır. Talep tahmini hotelin gelir yönetimi sisteminin bir parçası olarak ele alınmıştır ki bu yönetim sistemi gelirleri maksimize etmek için hotel odalarının yeni müşteriler için ne zaman ve hangi fiyattan hazır olacağını belirten bir karar destek sistemidir. Ayrıca araştırmacılar çalışmalarında hotel yöneticilerinin edindikleri tecrübeler sayesinde 2-3 haftalık periyotlar için oldukça doğru tahminler yaptıklarını ve bu bilgiyi çalışmalarında kullandıkları model ile ifade etmek istediklerini belirtmişlerdir [14].

Bir diğer çalışmada Greenidge 2001 yılında turizm sektöründeki talebi tahmin etmek için yapısal zaman serisi modelini kullanmıştır. Karayipler'de bulunan Barbados için turistlerin gelişine ilişkin tahmin yaptığı bu çalışma da turistlerin davranışları hakkında bilgiler ve örneklemeden elde ettiği güvenilir bir tahmin sunmuştur. Bununla birlikte Greenidge ilgili literatürde kullanılan önceki modellerde göz ardı edilen sezonsallığın önemini de vurgulamıştır [15].

Lim ve McAleer 2002 yılında Avustralya için uluslararası yolcu talep tahmini yapmışlardır. Çalışmalarında zaman serisi yöntemlerinden biri olan ARIMA (Autoregressive Integrated Moving Average - Otoresif Birleşik Hareketli

Ortalama) modelini kullanan arařtırmacılar alıřma sonularını ortalama hata karesinin kk ve ortalama mutlak yzde hata ile deęerlendirmişlerdir. alıřma sonularına gre ARIMA modeli Singapur iin bařarılı sonu verirken Malezya ve Hong Kong'dan gelen uluslararası yolcular iin Singapur kadar bařarılı sonular verememiřtir [16].

Ediger ve Tatlıdil 2002 yılında Trkiye'deki enerji talebini tahmin etmek iin dngsel desenler yntemini kullanmışlardır. Arařtırmacılar alıřmalarında Trkiye'de birok istatikselsel tahmin yntemlerinin enerji sektrnde sıklıkla kullanıldığı fakat alıřmalarında aıkladıkları bazı nedenlerden dolayı bu tahminlerin oęunlukla gerekleşenden fazla ıktığını belirtmişlerdir. Bu nedenle yarı istatikselsel bir analiz olan dngsel analiz yntemini uygulamışlar ve Winter'ın stel dzeltme yntemine olduka yakın bir sonuca ulaşmışlardır [17].

Altay vd. 2008 yılında aralıklı talepleri tahmin etmeye ynelik bir alıřma gerekleřtirmişlerdir. alıřmalarında Croston yntemi ile Holt'un ift stel dzeltmeli yntemini kullanmışlardır. Sonu olarak stok seviyelerini minimize etmek isteyen firmalar iin Croston modelinin kullanılması, mřteri hizmetlerini nceliklendiren iřletmeler iin ise Holt'un modelinin kullanılması nerilmiştir [18].

Thomas Ng vd. 2008 yılında yaptıkları alıřmalarında yapay zeka yntemlerinden biri olan genetik algoritma ve geleneksel kantitatif yntemlerden biri olan doęrusal regresyon modeli ile zel konut talep tahmini yapmışlardır. Ayrıca alıřmalarında bu iki modelin hibrit versiyonunu da kullanan arařtırmacılar genetik algoritmaya adaptif mutasyon oranının dahil olduęu ve doęrusal regresyon ile hibritlenmiş versiyonun dięer modellerden daha iyi sonular verdięini gstermişlerdir [19].

Helenik g sisteminin yk talebini tahmin etmek iin Pappas vd. 2010 yılında kantitatif tahmin yntemlerinden ARMA (Autoregressive Moving Average - Otoregresif Hareketli Ortalama) modelini kullanmışlardır. Elektrik yk talep tahmininin zaman serilerine uygun bir uygulama alanı olmasının nedenini veri setinin istatikselsel olarak zaman serilerine adapte edilebilmesi olarak aıklamışlardır.

Çalışmada kullanılan ve geliştirilen diğer modellerin hepsinin ortalama mutlak yüzde hataya ile değerlendirildiğinde başarılı sonuçlar verdiği belirtilmiştir [20].

Özer ve Erkilet 2012 yılında özel bir hastane için yaptıkları talep analizi ve tahmini çalışmasında istatistiksel analiz yöntemlerinden biri olan ki kare testi yapmışlardır. Uyguladıkları teste göre hastaların eğitim durumu ile bir sonraki sorunda hastaneyi tercih etmeleri arasında anlamlı bir ilişki bulunamamış fakat hastaların meslekleri ile bir sonraki sorunda hastaneyi tercih etme durumları arasında anlamlı bir ilişki bulunmuştur [21].

Bergman vd. 2017 yılında yeni ekipman programının talebini tahmin etmek için Bayes yaklaşımını kullanarak bir tahmin çalışması yapmışlardır. Çalışmalarında ele aldıkları yeni ekipman için talep bilgisi oluşturamadıklarından benzer ekipmanlara ait talepleri kullanan araştırmacılar uyguladıkları yöntemi geleneksel tahmin yöntemleri ile karşılaştırarak ve stok doluluk performansına bakarak değerlendirmişlerdir. Çalışma sonucuna göre Bayes tabanlı tahmin yöntemi parça tahmini, stok doluluk oranını ve stok maliyetlerini daha iyi tahmin edebilmiştir [22].

Bacci vd. 2019 yılında zaman serilerinin hibrit bir versiyonunu kullanarak Brezilya'nın kahve talebini incelemişlerdir. Birçok metodu birleştirerek kullandıkları çalışmalarında önerdikleri metodun tahmin ağırlıklarını belirlemede başarılı sonuçlar verdiğini belirtmişlerdir [23].

Yapay zeka yöntemlerinin kullanıldığı çalışmalar ise aşağıdaki gibi verilmiştir.

Law 2000 yılında yaptığı çalışmasında geri yayılım algoritmasını kullandığı bir yapay sinir ağı kullanarak turizm talep tahmini yapmıştır. Law yaptığı çalışmasında geleneksel yöntemlerin turizm alanında başarılı bir tahmin yapabildiğine belirtmiş fakat ileri beslemeli yapay sinir ağları ile bu tahminin daha doğru sonuçlar verdiğini belirtmiştir. Yaptığı çalışmada ise, önceki çalışmaları referans alarak geliştirmeler yapmış ve talep tahminini geri beslemeli yapay sinir ağları ile gerçekleştirmiştir. Çalışma sonucunda elde ettiği verilere göre geri beslemeli yapay sinir ağları, geleneksel talep tahmin yöntemleri olan regresyon, zaman serileri gibi yöntemlere

göre daha iyi performans göstermiş ve ileri beslemeli yapay sinir ağına göre ise daha doğru tahminler yapmıştır [24].

Darbellay ve Slama 2000’de yapay sinir ağlarının popüler olmaya başladığı yıllarda yaptıkları çalışma ile literatürde sıkça sorulan soruya cevap vermeye çalışmışlardır. Yapay sinir ağları daha iyi tahminde bulunabilir mi? Araştırmacılar çalışmalarında geleneksel doğrusal tahmin modellerinden ARIMA ve doğrusal olmayan tahmin modeli olan yapay sinir ağlarını kullanarak Çekya’nın elektrik yükü için tahmin çalışması yapmışlardır ve Çekya’nın elektrik yükünün doğrusal bir problem olduğunu belirtmişlerdir. Bu nedenle ARIMA yönteminin daha iyi bir sonuç vermesi olağandır [25].

Akyurt 2015 yılında Türkiye tarafından üretilmesi planlanan yerli otomobil için yapay sinir ağları kullanarak talep tahmini çalışması yapmıştır. Ocak 2011 ile Eylül 2015 yılları arasında oluşan yerli otomobil satışının analizini yaparak bir model oluşturmuş ve ortalama mutlak yüzde hata ile ortalama hata kare yöntemleri ile modelin performansını ölçmüştür [26].

2015 yılında Türkiye’nin Malatya ilinde yetiştirilen kuru kayısıların ihracat talep miktarını yapay sinir ağları ile tahmin etmek için çalışma yapan Karahan elde ettiği sonuçları geleneksel yöntemlerden biri olan ARIMA modeli ile karşılaştırmış ve test sonrası yaptığı hata analizi ile kurduğu modelin güvenilirliği ve tutarlılığını göstermiştir [27].

Günay 2016 yılında yıllık elektrik talep tahminini yapay sinir ağları kullanarak yapmıştır. Çalışmasında Türkiye’nin sosyo-ekonomik durumunu ve iklim koşullarını da modeline dahil eden Günay çalışması sonucunda kurduğu modeli gerçekleşen veriler ile karşılaştırarak başarılı bir sonuç almıştır ve 2028 yılına kadar yaptığı çalışma sonucuna göre talebin ikiye katlanacağı sonucuna ulaşmıştır [28]

Akkol vd. 2017 yılında literatürde yer alan çalışmalardan farklı bir alanda tahmin çalışması yapmıştır. Kıl keçilerinin canlı ağırlık tahmini için yapay sinir ağları ve çoklu doğrusal regresyon kullanan araştırmacılar yaptıkları analiz sonucunda yapay

sinir ağlarının çoklu doğrusal regresyon modeline göre daha başarılı sonuçlar verdiğini belirtmişlerdir [29].

Tanizaki vd. 2019 yılında bir restoran için makine öğrenmesi yöntemini kullanarak talep tahmini yapmışlardır. Çalışmalarında literatürdeki benzer çalışmalarda kullanılan modellerin talebi etkileyen lokasyon, hava durumu, etkinlik gibi değişkenleri dikkate almadığını fakat çalışmaların başarılı sonuçlar verebilmesi için bu değişkenlerin de modele dahil edilmesi gerektiğini belirtmişlerdir [30].

Literatürde incelenen çalışmaların çoğu enerji ve turizm talebine yönelik tahminleri içermektedir. Ayrıca yapılan literatür incelemesinde görüldüğü üzere günümüzde yapılan çalışmaların çoğu yapay zeka sistemleri ile yapılsa da geleneksel yöntemler de hala tercih edilmektedir.

Satış tahmini alanında da sıklıkla kullanılan yapay sinir ağları Tüzüntürk vd. tarafından 2016 yılında damacana su satış miktarını tahmin etmek amacıyla kullanılmıştır. Çalışma sonucunda eğitilen yapay sinir ağından elde edilen veriler gerçek verilerdeki sezonsallığı yakalamışlardır [31].

Ecemiş ve Irmak 2018 yılında paslanmaz çelik sektörü için yapay sinir ağlarının da bulunduğu bir takım veri madenciliği yöntemleri kullanmış ve bu yöntemler sonucunda destek vektör regresyon yönteminin yapay sinir ağları yöntemine göre daha başarılı sonuçlar verdiği gözlemlenmiştir [32].

2019 yılında bir diğer perakende sektörü olan yiyecek ve içecek sektöründe yapılan çalışmada Sönmez ve Zengin yapay sinir ağları ve regresyon modelleri kullanarak talep tahmini yapmışlardır. Her iki yöntemde de modelin başarı modelleri yüksek bulunmuş yapay sinir ağlarında test oranı %95,77 olarak bulunmuştur. Çoklu regresyon modelinde ise doğruluk oranı %91,3 olarak çıkmıştır. Buna göre yapay sinir ağlarının daha başarılı bir sonuç verdiği gözlemlenmiştir [33].

Kuo ve Xue 1999 yılında bulanık sinir ağları kullanarak satış tahmini çalışması yapmışlardır ve bu çalışmalarında dönemin tekniklerine karşın kullandıkları sinir



ağları ile istatistiksel modellere oranla başarılı sonuçlar elde ettiklerini belirtmişlerdir. Araştırmacılar yaptıkları çalışmada önerilen talep tahmini modeli için verilerin toplanması, yapay sinir ağları, bulanık sinir ağları ve karar desteği sağlayan yapay sinir ağı modeli olmak üzere dört parçadan oluşan bir sistem oluşturmuşlardır [34].

Green ve Harrison 1973 yılında, çok uzak olmayan geçmişte yaptıkları çalışmalarında posta ile satış yapan bir firma için Bayes yöntemini kullanarak tekstil sektöründe talep tahmini yapmıştır. Farklı tarzda kadın elbiselerini altı aylık bir süre için kataloglayan, müşterilere dağıtan ve bu kataloglardan sipariş kabul eden firma, bu siparişleri zamanında teslim edebilmek için ise ilk birkaç haftada malzeme siparişi vermek zorundadır. Bu şartlar altında hangi elbiselerin daha fazla satacağını tahmin etmek ve buna göre malzeme siparişi vermek ilgili firma için oldukça önemli bir problemdir. Bu problemin çözümü için ise araştırmacılar Bayes yaklaşımını kullanmıştır [35].

Frank vd. 2003 yılında matematiksel modelleme kullanarak kadın giyim ürünlerinin tahmini için bir çalışma yapmışlardır. Araştırmacılar yaptıkları çalışmada geleneksel tahmin yöntemlerinin sadece geçmiş satış adetlerini göz önünde bulundurarak tahmin yapması fiyat, renk, hava durumu, enflasyon gibi etkenleri göz ardı etmesi ve doğrusal regresyon modellerinin bu etkenleri sınırlı olarak dikkate alması nedeniyle talep tahminlerinin başarısını sorgulamışlardır. Çalışmalarında yapay sinir ağları ve geleneksel yöntemler ile kadın giyim ürünlerinin satışlarını tahmin etmişler ve sonuçları karşılaştırmışlardır. Geleneksel yöntemlerden üstel düzeltme yöntemi ile elde edilen uygunluk değeri 0.75 ve Winter yöntemi ile elde edilen uygunluk değeri 0.90 olurken, yapay sinir ağları ile elde edilen uygunluk değeri 0.92 olarak elde edilmiştir. Buna rağmen gerçek veri ile tahmin edilen veri arasındaki korelasyon yapay sinir ağına Winter modeline göre daha düşük çıkmıştır [36].

Thomassey ve Fiordaliso 2006 yılında yaptıkları çalışmada tekstil sektöründe kısa ömürlü ürünler ve çok fazla yeni ürün olması sebebi ile geleneksel tahmin yöntemlerinin yetersiz kaldığını belirtmişlerdir. Bu nedenle orta vadeli bir tahmin yapabilmek için kümele ve sınıflandırma araçlarını kullanmışlar ve Fransız tekstil firmasının verilerini kullanmışlardır [37].

Sabır ve Batuk 2013 yılında tekstil boya terbiye işletmelerinde zaman serileri kullanarak en uygun talep tahmini modelini bulmayı amaçlamışlardır. Çalışmada kullanılan gerçek verilerde gözlemlendiği kadarı ile talebin sezonsal değiştiği ve bazı ürün gruplarında ise bir eğilime sahip olduğu belirtilmiştir. Winter's modeli, basit trend düzeltmeli üstel düzeltme yöntemleri kullanılan çalışmada en doğru talep tahmin yöntemi olarak basit üstel düzeltme yöntemi belirlenmiştir [38]. Bir diğer çalışmada ise Kalaoğlu vd. 2015 yılında Türkiye'nin tanınmış bir perakende markası için geçmişteki satış verilerini referans alarak doğrusal eğilim modeli, basit hareketli ortalama ve ağırlıklı hareketli ortalama yöntemlerini kullanarak satış tahmini yapmışlardır. Geleneksel talep tahmini yöntemleri kullanılan bu çalışmada satış dönemleri ve satış adetlerinin olduğu iki değişken kullanılmış fakat satışı etkileyebilecek diğer etkenler göz ardı edilmiştir [39].

Li ve Lim 2018 yılında doyumsuz toplama ve ayrıştırma algoritması kullanarak tekstil perakendecisi için aralıklı talep tahmini uygulaması yapmışlardır. Yeni bir yaklaşım önerisinde bulunan araştırmacılar bu yeni modelin ayrıca aralıklı-kesitli zaman serisi tahminleri için de kendini geliştirdiğini belirtmişlerdir. Ayrıca araştırmacılar performans ölçümü için revize edilmiş ortalama mutlak hata yöntemi önermişlerdir [40].

Ren vd. 2019 yılında moda ürünleri satan bir perakendeci için talep tahmini çalışması yapmışlardır. Çalışmalarında bahsettikleri üzere tekstil perakende sektörü için yapılan çalışmaların hem akademi hem de endüstri için oldukça zor olduğu vurgulanmış ve büyük veri kavramı ile bu zorluğun aşılabacağı düşünülmektedir. İlgili çalışmada araştırmacılar tekstil perakende endüstrisi için yapılan talep tahmini çalışmalarını incelemiş ve son olarak bir uygulama yapmışlardır. Bu çalışma literatürde karşılaşılan, tekstil endüstrisine yönelik talep ya da satış tahminini içeren en geniş kapsamlı çalışmalardan biri olarak dikkat çekmiştir [41].

Meza vd. 2019 yılındaki çalışmalarında Kolombiya'da yer alan Bogota şehri için kentsel katı atıkların yok edilmesi süreçlerini tahmin etmek için tahmin edici modellerden karar ağaçları tabanlı makine öğrenmesi, destek vektör makineleri ve yapay sinir ağlarını kullanmışlardır. Çalışmanın temel amacı şehirdeki katı atıkların

toplanması, taşınması ve yok edilmesi hususunda karar verme stratejisi oluşturulmaktadır. Çalışmada kullanılan yöntemlerin seçiminde, eldeki verilerin non-parametrik veriler olduğu belirtilmiştir. Çalışma sonucunda destek vektör makinelerinin en uygun model olduğu belirtilmiştir [42].

Tünellerdeki sınılaşmaya bağıli yükselme ve yer deęiřtirmenin tahmin edilmesi amacıyla Zheng vd. 2020 yılındaki çalışmalarında yapay sinir aęları ve destek vektör makinaları kullanmışlardır. Modellerin performansının ölçülmesinde ise  $R^2$ , ortalama mutlak hata (MAE) ve hataların ortalama karekökü (RMSE) performans kriterleri kullanılmıştır [43].

Shao vd. 2020 yılında yaptıkları çalışmalarında hotel binalarındaki enerji tüketiminin tahmini için destek vektör makinaları kullanmışlardır. Yapılan çalışmalar sonucunda ortalama hataların karesi %2,22 ve  $R^2$  deęeri ise 0,94 olarak tatmin edici bulunmuştur [44].

Baba ve Güven 2020 yılında yaptıkları çalışmalarında řirketlerin ilk halka arzının řirketlere olan dönüşünü tahmin etmek için rastgele ormanlar algoritmasını kullanmışlardır. Çalışmalarında bu dönüşlerin büyük ölçüde doğrusal regresyon modellerine bağıli olduğunu belirten arařtırmacılar, çalışmalarında güçlendirilmiş regresyon ile rastgele ormanlar modellerinin sonuçlarını karşılařtırmışlardır. Rastgele ormanlar yönteminin çok daha iyi sonuçlar verdiği gözlemlenmiştir [45].

Bir dięer kapsamlı çalışma 2013 yılında Liu vd. tarafından yapılmıştır. Tekstil perakende sektörü için satış tahmini alanında yapılan çalışmaların incelendięi bu literatür çalışmasında tahminin geçmiş 15 yıllık deęişimi irdelenmiştir. İstatiksel tahmin araçlarından en çok kullanılanın ARIMA ve SARIMA (sezonsal otoregresif birleşik hareketli ortalama) yöntemleri olduğunu belirten arařtırmacılar bunun nedenini ise ilgili yöntemlerin basit bir şekilde uygulanabilmesi ve çok çabuk bir şekilde sonuca ulaşması olarak belirtmişlerdir. Bu iki modelin dışında Bayes yaklaşımı da sıklıkla kullanılan bir yöntem olarak öne çıkmıştır. Tüm avantajlarının yanında hangi istatiksel modelin seçileceęi bu yöntemlerin dezavantajlarından biri olarak ifade edilmiş ve uzman bilgisi gerektięi belirtilmiştir. Dięer bir dezavantaj ise

sonuçların başarısının düşük olmasıdır. En önemli dezavantajlardan biri ise trend, sezonsallık gibi tekstil ve moda endüstrisine özel etkenlerin istatistiksel yöntemler tarafından başarılı bir şekilde modellenememesidir. Tekstil perakende satışlarının tahmini problemleri için kullanılan diğer yöntemler ise yapay zeka yöntemleridir ve uygulama alanları her geçen gün artmaktadır. Literatürde en çok kullanılan yapay zeka tahmin yöntemleri yapay sinir ağları ve bulanık mantığa dayalı modellerdir. Yapılan çalışmalar gösteriyor ki yapay sinir ağları tahmin modelleri arasında en başarılı olan yapay zeka yöntemlerinden biridir. Liu vd. yaptıkları literatür çalışmasında evrimsel sinir ağları, geri beslemeli sinir ağları ve ileri makine öğrenmesi yöntemlerinin de geniş bir kullanım alanı olduğunu belirtmişlerdir. Ayrıca literatürde istatistiksel yöntemler ile yapay zeka tabanlı yöntemlerin birlikte kullanıldığı ya da farklı iki yapay zeka yönteminin birlikte kullanıldığı hibrit modellerde mevcut çalışma kapsamında incelenmiştir [46].

Uluslararası literatür incelendiğinde tekstil ya da moda perakende sektörü için yapılan istatistiksel [47–50] ve yapay zeka tabanlı [42,43,57,44,45,51–56] tahmin çalışmaları tekstil ya da moda ürünleri için satış tahminin zorluğu hakkında bir fikir vermektedir. Literatür incelendiğinde görüldü ki tekstil perakende endüstrisinde doğru bir tahmin yapmak için satışı etkileyebilecek ürün, renk, beden, desen, hava durumu, enflasyon, gibi birçok etkenin kurulacak tahmin modelinde dikkate alınması gerekmektedir. Sadece satış adetlerine göre yapılan talep ya da satış tahminleri kısa dönemde başarılı olsa da uzun dönemde doğru sonuçlar vermemektedir.

Bu nedenle bu çalışmada önerilen modelde tahmin çalışması yapılacak ürünler için renk detayına inilecek ve renk bazında satış adetleri dikkate alınacaktır. Renk detayının yanında tekstil ürünlerinin satışı üzerinde etkisi olabilecek hava durumu bilgisi, ürünün satış fiyatı, mağazadaki stok durumu, ilgili haftada özel gün olup olmaması gibi detaylar ile birlikte ülkenin ekonomik konjonktürünü etkileyebilecek döviz kuru, faiz oranı, tekstil ürünleri için üretici ve tüketici fiyat endeksi gibi değişkenler de modele dahil edilecektir. Önerilen tahmin modelinde yapay sinir ağları, destek vektör makinaları ve rastgele ormanlar yöntemleri ile tahmin çalışması yapılacak ve renk detayının dahil olduğu veri seti ile renk detayının dahil olmadığı

veri seti olmak üzere iki farklı veri üzerinde tahmin modelleri çalıştırılacaktır. Renk detayının tahmin performansını olumlu yönde etkilemesi beklenmektedir.

## BÖLÜM 3

### YAPAY ZEKA İLE TALEP TAHMİN YÖNTEMLERİ

Yapay zeka teknikleri bilgisayarların geliştirilmesiyle birlikte 1950’li yıllarda ortaya çıkan kavramlar ve algoritmalar sonucu oluşmuş, günümüzde çok yaygın bir kullanım alanına sahip olmuştur. Endüstriyel alanlarda kullanımın ardından, günlük yaşantımızın da bir parçası haline gelen yapay zeka, sınıflandırma, regresyon, görüntü işleme, ses işleme, otonom sürüş, metin madenciliği gibi bir çok alt alanda kullanılmaktadır. Bu bölümde yapay zeka tekniklerinden tahmin edici, regresyon modellerinde kullanılan yapay sinir ağları (YSA), destek vektör makineleri (DVM, Support Vector Machines-SVM) ve rastgele orman (RO, Random Forests-RF) yöntemleri açıklanacaktır.

#### 3.1. YAPAY SİNİR AĞLARI

Yapay sinir ağları (YSA) insan beyninin çalışma mantığından hareketle sinirlerin hareketlerini taklit ederek öğrenme, genelleme, hatırlama, yeni bilgiler oluşturma gibi aktiviteleri gerçekleştirmek için geliştirilen bilgisayar sistemleridir. Bu yetenekler geleneksel programlama yöntemleri ile oluşturulması mümkün olmayan yeteneklerdir.

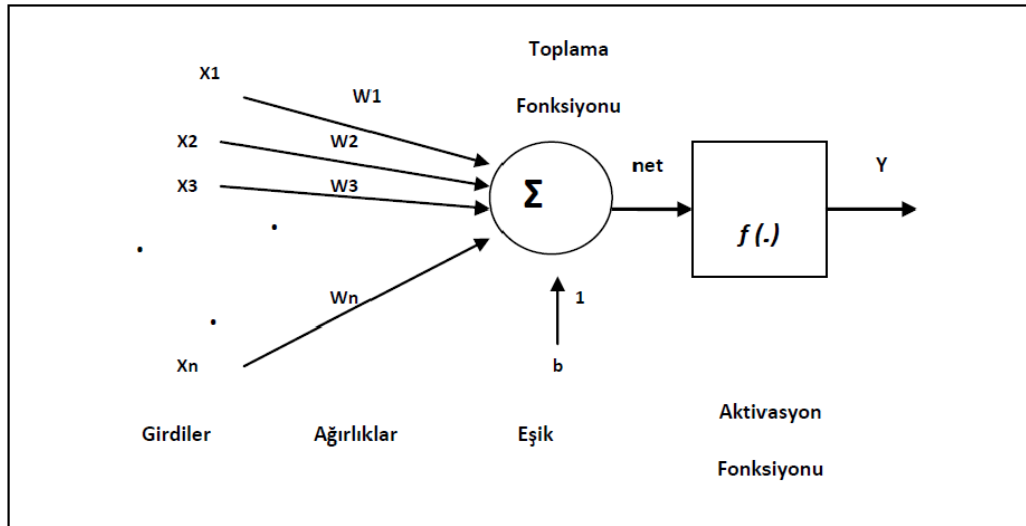
##### 3.1.1. Yapay Sinir Ağları Temel Kavramlar

Yapay sinir ağları insan beyninde yer alan gerçek sinir hücrelerinin modellenmesi ile oluşturulmuş yapay yapılardır. Yapay sinir ağları örnek olayları inceler, veri setinden genellemeler yapar, bilgi toplar ve kaydettiği bu bilgiler sayesinde daha önce hiç karşılaşmadığı örneklere bakarak geçmiş bilgilerini kullanarak kararlar verir. Geliştirilme nedeni insan aklının bilişsel yeteneklerinin bilgisayarlar ile sanal ortamda taklit edilmesidir. Yapay sinir ağları tahminleme, kümeleme, sınıflandırma

gibi birçok problem için çözüm olmuşlardır. Yapay sinir ağları en temel özelliği geçmiş verilerden öğrenerek problemlere çözüm üretme yetenekleridir [58].


Yapay sinir ağları insan beyninde olduğu gibi paralel düşünce yeteneğini simüle ederek birbirine bağlı çok işlemcili ünitelerin oluşturduğu bir sistemdir. Yapay sinir ağları bir çok literatürde yapay zeka sistemleri altında incelenmektedir. Yapay sinir ağları klasik yöntemlerin çözemediği problemlerin çözümü için kullanılabilir. Yapay sinir ağının sahip olduğu bir hücre giriş verilerini doğrusal olmayan bir çıkış olarak verir. Yapay sinir ağının giriş ve çıkış hücreleri arasındaki bağlantının bilinmemesi ve doğrusal olmaması nedeniyle black box olarak nitelendirilmektedir [59].

Yapay sinir ağları birçok sinir hücresinin bir araya gelmesinden oluşur ve sinir hücresi en küçük işlem birimidir. Her işlem birimi birbirlerine bağlıdır ve basit hesaplamalar yapabilirler. Yapay sinir ağının sonucu birçok sinir hücresinin yani işlem biriminin ortak bir sonucu olarak elde edilir. En basit sinir ağı hücresi girdi, ağırlık, birleştirme fonksiyonu, transfer fonksiyonu ve çıkış bileşenlerinden oluşmaktadır. Şekil 3.1’de basit bir sinir hücresini gösterilmektedir.



Şekil 3.1. Yapay sinir hücresi [60].

Yapay sinir ağı, yapay sinir hücrelerinin birbirlerine bağlanması ile oluşmaktadır ve yapay sinir hücreleri arasındaki bağlantılar ağırlıklar ile kurulmaktadır. Ağırlıklar temel olarak iki yapay sinir hücresi arasındaki ilişkinin kuvvetini belirler. Bu ilişkiler insan beyninin sinir hücrelerinde olduğu gibi kuvveti artırılabilir ya da azaltılabilir. Ağırlığın büyük olması ilgili girişin önemli ya da önemsiz olması üzerinde etkili olmayabilir. Bazı durumlarda düşük ağırlıklar ya da ağırlığı 0 olması ağına tüm çıkışı etkileyebilmektedir. Ağırlıklar negatif ya da pozitif değerler alabilir sabit ya da değişken olabilirler. Yapay sinir hücreleri yapay sinir ağlarının tamamını temsil etmezler. Yapay sinir hücreleri yapay sinir ağında katmanların içerisinde yer alır. Bir yapay sinir ağı en az bir giriş katmanı, bir çıkış katmanı ve gizli katman olmak üzere 3 katmandan oluşur (Şekil 3.2). Gizli katman sayısı, yapay sinir ağının yapısına ve problemin tipini göre farklılık gösterebilir fakat derin öğrenme teknikleri hariç yapay sinir ağlarında çok fazla gizli katman olması istenmez. Gizli katmanlar ağırlıkların da etkisiyle yapay sinir ağının öğrenme geçmişine ait verileri tutarak giriş bilgilerinin yorumlanmasını ve çıkışa aktarılmasını sağlar. Giriş katmanından aktarılan bilgiler gizli katmanlarda işlem görür ve çıktı katmanına iletilirler. Bir yapay sinir ağı  $n$  adet giriş katmanına ve  $n$  adet çıkış katmanına sahip olabilir.



Şekil 3.2. Yapay sinir ağlarının yapısı [59].



Yapay sinir ağlarının her zaman başarılı olduğu gözlemlenememektedir. Bunun birkaç sebebi olabilir, bunlardan bazıları giriş verilerinin yeterli olmaması, eğitim tekrarının yeteri kadar yapılmaması, ya da eğitim verilerinin yeterli olmaması gibidir. Çok fazla gizli katmana sahip yapay sinir ağlarında da eğitim verilerinin ezberlenmesi ve yapay sinir ağının başka veriler ile karşılaştığında vereceği tepkileri olumsuz etkilemektedir. Bu gibi durumlarda gizli katmanların sayısının azaltılması önerilmektedir [59].

### **3.1.2. Yapay Sinir Ağlarının Tarihi Ve Özellikleri**

Yapay sinir ağlarının temelleri 1943 yılında bir nörolog ve bir bilim insanı Warren McCulloch ve Walter Pitts tarafından insan beynini taklit edilmesi amacıyla geliştirilmiştir. Sonraları Hebbian öğrenme kuralı olarak isimlendirilen ve Hebb tarafından geliştirilen öğrenme teorisi yapay sinir ağlarında yapay sinir hücreleri arasında kurulan bağlantıların sayısının değiştirilmesi sayesinde öğrenme işleminin gerçekleşebileceğini belirtmektedir. 1958 yılında Rosenblatt tarafından geliştirilen perceptron yapay sinir ağlarının tarihsel gelişimi açısından devrim niteliğinde bir çalışma kabul edilmektedir. Perceptron temelde şekil tanıma amacıyla yazılan tek katmana ve tek çıkışa sahip eğitilebilen bir yapay sinir ağıdır ve günümüzde uygulanan çok katmanlı derin öğrenme alanında faaliyet gösteren yapay sinir ağlarının temelini oluşturmaktadır. Yapay sinir ağlarının mühendislik alanında ilk kullanımı ise 1959 yılında Widrow ve Hoff tarafından adaptif doğrusal nöron modelinin oluşturulmasıyla olmuştur. Kısaca ADALINE (Adaptive Linear Neuron) olarak adlandırılan bu modelin çok katmanlı versiyonu MADALINE olarak isimlendirilmiştir. 1982 yılında Hopfield geleneksel yöntemler ile çözülemeyen XOR (Exclusive OR) problemlerini çok katmanlı yapay sinir ağları sayesinde çözerek yapay sinir ağlarına karşı olan önyargıları yok etmiştir. 1986 yılında Rumelhart ve arkadaşları yapay sinir ağları için sıklıkla kullanılan geri yayılım algoritmasını geliştirmişlerdir. Bu geri yayılım algoritması halen günümüzde en çok kullanılan yapay sinir ağları algoritmalarından biridir. İlerleyen yıllarda geliştirilen radyal temelli fonksiyonlar ve olasılıklı yapay sinir ağları da yapay sinir ağlarının gelişmesine katkı sağlamıştır. Günümüzde teknolojinin de gelişmesiyle üretilen güçlü donanımlar kullanılarak derin öğrenme algoritmaları geliştirilmiş ve kullanım

sıklığı artmıştır. Yapay sinir ağıları genetik algoritma, bulanık mantık gibi diğer yapay zeka teknikleri ile hibritlendiğinde daha iyi sonuçlar sunabilmektedir [60,61].

Yapay sinir ağlarının nasıl oluşturulacağı hakkında kesin bir kabul olmamakla birlikte probleme ve veri setine uygun yapay sinir ağları deneme yanılma yöntemi ile ya da literatürdeki çalışmalar ve kabuller referans alınarak oluşturulabilir. Bir yapay sinir ağındaki gizli katman sayısı olması gerekenden fazla ise bu durum yapay sinir ağının ezber yapmasına ve yeni veriler karşısındaki tahmin gücünü düşürmesine neden olabilmektedir. Gizli katman sayısının yetersiz olması ise problemin ya da fonksiyonun çözümünde yapay sinir ağının yetersiz kalmasına neden olabilir. Yapay sinir ağlarının kurulması sırasında karşılaşılan bir diğer problem ise katmanların içerisinde yer alan sinir hücrelerinin belirlenmesidir. Girdi katmanında girdi sayısı kadar yapay sinir hücresi ve çıktı katmanında ise arzu edilen çıktı miktarı kadar yapay sinir hücresi vardır. Fakat yapay sinir ağlarının yapısı gereği gizli katmanlarda ne olduğu bilinmemektedir ve bu nedenle gizli katmanlarda yapay sinir hücresi hesaplanamamaktadır. Buna karşın en ideal yapay sinir hücresini hesaplayabilmek adına uygun bir yöntem de bulunmamaktadır [58].

Yapay sinir ağlarının literatürde yer alan birçok avantajı ve dezavantajı mevcuttur [58,60,61].

Yapay sinir ağlarının en temel özellikleri arasında eş zamanlı çalışma yer almaktadır. Geleneksel yöntemlerde algoritmalar problem çözümü için iterasyonlar ile adım adım çözüme ilerler iken yapay sinir ağlarında ise tüm yapay sinir hücreleri eş zamanlı çalışarak problemlerin çözümüne hızlı bir şekilde ulaşabilmektedir. Yapay sinir ağları yapıları gereği insan beynini taklit etmektedirler.

İnsan beyni geçmişte öğrendiği verileri yeni bir durum karşısında hatırlayarak tepki üretebilir. Yapay sinir ağları da benzer şekilde eğitim aşamasında öğrendiği verileri kullanarak yeni olaylar karşısında tepkiler üretebilir ve yanıtlar verebilir. Eğitimi tamamlanmış bir yapay sinir ağı giriş verilerinin eksik olması durumunda bile giriş verisine en yakın veriyi öğrenme geçmişinden çağırışım yaparak tamamlayabilir ve

uygun tepkiyi üretebilir. Buna yapay sinir ağlarının genelleştirme özelliği denilmektedir.

Yapay sinir ağları doğrusal olmayan modellerdir ve bu nedenle gerçek hayatta karşılaşılan problemlere daha gerçekçi çözümler üretebilirler. Bu özellikleri sayesinde yapay sinir ağları tahminde bulunabilme yeteneğine sahiptir ve istatistiksel hesaplamalara göre daha iyi sonuçlar vermeleri nedeniyle tahmin alanlarında oldukça sık başvurulmaktadır.

Yapay sinir ağlarının bir diğer özelliği ise öğrenme yeteneğidir. İnsan beyni ile benzer bir şekilde hareket eden yapay sinir ağları doğru sonuçlar için doğru bağlantılara ve ağırlıklara sahip olmalıdır. Bu bağlantıların ve ağırlıkların ilk başta doğru olarak tanımlanması mümkün değildir. Yapay sinir ağları eğitim verileri ile kendilerini eğiterek problemi öğrenir.

Yapay sinir ağları yapay sinir hücrelerinin paralel şekilde birbirlerine bağlanması sonucu oldukça esnek bir yapıya sahiptir. Böylece yapay sinir ağlarının belirli bir katmanında meydana gelen hatalar diğer katmanların çalışmaya devam etmesi nedeniyle göz ardı edilerek sonuç üzerinde olumsuz bir etkiye sahip olmazlar.

Sistemlerin her an değişmesi ya da gerçek zamanlı olarak verilerin işlenmesi muhtemeldir. Yapay sinir ağları bu durumda tekrar eğitilerek ağırlıkların yeniden ayarlanması sağlanabilir. Eğer çalışılan sistem gerçek zamanlı ise eğitim de gerçek zamanlı olarak devam eder.

### **3.1.2.1. Yapay Sinir Ağlarının Avantajları ile Dezavantajları**

Yapay sinir ağları gelenekselleşmiş yöntemlerin çözemediği problemler için çözüm üretebilme yetenekleri ile birçok avantaj sağlamaktadırlar. Net bir şekilde görülemeyen, göz ardı edilen etkenler ve bağlantılar klasik yöntemler ile gözden kaçırılabilirken yapay sinir ağları bu bağlantıları kurabilir ve probleme uygun çözüm üretebilirler. Giriş verilerinin eksik olması ya da kendi başlarına öğrenme yetenekleri de yapay sinir ağlarını klasik yöntemlere göre daha tercih edilir olmasının

nedenlerindedir. Yapay sinir ağlarının diğer avantajları aşağıdaki gibi listelenmektedir [60,61].

1. Yapay sinir ağları eksik olan giriş verilerini eğitim setinden aldığı veriler ile benzeştirerek tamamlayabilme yeteneğine sahiptir.
2. Yapay sinir ağları problemleri diğer klasik yöntemlere göre daha hızlı çözerler.
3. Veri değişikliklerine ya da diğer etkenlere tepki vererek yapay sinir hücreleri arasındaki bağlantıların ağırlıklarını değiştirebilir ve öğrenme yeteneğini kullanabilir.
4. Lineer yapıda olmadıkları için gerçek problemlere uygulanabilirliği yüksektir.
5. Kümeleme, tahminleme, genelleme, sınıflandırma ve örüntü tanıma gibi alanlarda başarılı sonuçlar vermektedir.
6. Hata tahammülü yüksektir, yapay sinir ağının belirli bir kesiminde meydana gelen bozulma ağın tamamına yayılmaz ve yapay sinir ağı bu bozulmadan etkilenmeden çalışmasına devam edebilir.
7. Yapay sinir ağları eş zamanlı çalışabilen yapay sinir hücrelerinden oluşmaktadırlar.

Literatürde yer alan bazı çalışmalar ise yapay sinir ağlarının bazı dezavantajlarını ortaya koymaktadırlar. Bu dezavantajlar aşağıdaki gibi sıralanabilir [58,60,61].

1. Yapay sinir ağlarının oluşturulma aşamasında ilgili model seçimi için kesin bir yöntem olmaması ve modelin deneme yöntemiyle bulunması yapay sinir ağlarının dezavantajlarından biridir. Yapay sinir ağları birçok öğrenme algoritmalarına, ağ yapılarına ve değişkenlere sahiptir. Eğer probleme uygun bir model seçilemez ise yapay sinir ağının başarılı olma şansı düşüktür.
2. Yapay sinir ağlarında doğru model seçilse bile problemlerin yapısı ya da eğitim verilerinin yetersizliği gibi nedenlerden dolayı doğru bir çözüme ulaşamayabilir.

3. Yapay sinir ağıları bünyelerinde bulundurdukları gizli katmanlar nedeni ile problemlerin çözümüne ilişkin net bilgiler veremezler ve açıklanamazlar. Literatürde “black box” ya da kapalı kutu olarak adlandırılmaktadırlar.
4. Yapay sinir ağıları paralel yapıya sahip olduklarından dolayı çok fazla güç tüketimine gereksinim duyabilirler, bu nedenle donanımsal açıdan ihtiyaçları yüksektir.
5. Yapay sinir ağlarında eğitim, problem çözümünün en önemli aşamalarından biridir. Fakat yapay sinir ağının ne kadar eğitilmesi gerektiği ile ilgili kesin bir bilgi yoktur. Bazı durumlarda karmaşık veriler ve veri sayısının çokluğu da yapay sinir ağlarının öğrenmesini yavaşlatabilir.


### **3.1.3. Yapay Sinir Ağlarının Temel Yapısı Ve Bileşenleri**

Yapay sinir ağları ile insan beyinin yapısı temelde birbirine benzerdir. Yapay sinir ağları insan beyninin modellenmiş versiyonudur ve insan düşünce ve öğrenme yapısını taklit eder. Bu nedenle yapay sinir ağlarının yapısını anlayabilmek için insan sinir hücresinin incelenmesi gerekmektedir.

İnsan beyni henüz çalışma mantığı anlaşılammış gizemli bir çalışma alanıdır ve düşünme, geriye dönük bilgileri hatırlama ve uyarılma gibi özelliklere sahiptir. İnsan beyinde  $10^{10}$  sinir hücresi olduğu ve  $6 \times 10^{13}$  adetten daha fazla bağlantı olduğuna dair bilgiler mevcuttur [58,60]. Bu sinir hücreleri ve aralarındaki bağlantıların çokluğu insan aklının gücünün kaynağını oluşturmaktadır. Her bir yeni öğrenme yeni bir bağlantı anlamına gelmektedir. Yapay sinir ağlarında kullanılan ve yapay sinir hücreleri arasındaki ilişkileri kurmaya yarayan ağırlıklar insan beyinde sinapslara karşılık gelmektedir ve bu ağırlıkların birbirlerine bağladığı yapay sinir hücreleri ise nöronları sembolize etmektedir. İnsan beyni, insan vücudunun sensörleri kabul edilen duyu organları aracılığıyla topladığı bilgileri sinapslar ile tutarak nöronlar arasında bağlantı kurarak işler ve öğrenilmiş veriler ile kıyaslayarak algılar ve anlar, gerekirse yeni sinapslar kurarak öğrenmek işlemini gerçekleştirir.

İnsan duyu organları yapay sinir ağlarındaki giriş katmanına karşılık gelmektedir. Çıkış katmanı ise insanın duyu organlarıyla algıladığı çevresel sinyallere verdiği

tepkiler olarak ifade edilmektedir. İnsan sinir hücresinin üçüncü katmanı ise duyu organları aracılığı ile algılanan çevresel sinyalleri işleyerek tepkilere dönüştüren merkezi sinir sistemidir ve yapay sinir ağlarındaki gizli katmanlara karşılık gelmektedir. Biyolojik sinir hücreleri olan nöronlar hücre gövdesine sahiptirler. Bu hücre gövdesi içerisinde sinapslar, aksonlar ve dendritler yer alabilir. Dendritler bir uzantı biçimindedir ve diğer nöronlardan aldıkları bilgileri parçası olduğu nöronun gövde kısmına taşır. Taşınan bu bilgiler nöron içerisinde değerlendirilerek bir sonuca varılır ve çıkış sinyali üretilir. Üretilen çıkış sinyali ise aksonlar yardımı ile diğer nöronlara taşınır. Akson nöronda sadece bir tane olabilirken dendritler birden fazla olabilir. Sinapslar hücreler arasındaki bağlantıyı kuran köprülerdir ve bu köprüler aksonlar ile dendritler arasında yani girişler ile çıkışlar arasında kurulur. Şekil 3.3'te biyolojik sinir hücresi yapısı verilmiştir [60].



Şekil 3.3. Biyolojik sinir hücresinin yapısı [58].

Yapay sinir ağları da nöronlar ile benzer yapıda tasarlanmışlardır ve insan beyninin çalışma mantığı ile hareket ederek sonuçlar üreten veri işleme merkezleridir. Yapay sinir ağları, giriş, çıkış, ağırlık toplama ve transfer fonksiyonu gibi eğrisel ya da doğrusal elemanlardan oluşurlar. Yapay sinir ağları yapı itibari ile üç katmandan oluşmaktadır. Bu katmanlar giriş katmanı, çıkış katmanı ve toplama ile transfer fonksiyonlarının yer aldığı gizli katmanlardır.

Bazı yapay sinir ađları ise katmanlar arasındaki iliřkiye gre isimlendirilmektedir. Eđer yapay sinir ađı ierisindeki veri akıřı ileriye dođru ise ileri beslemeleri yapay sinir ađları, veri akıřı belirli bir noktada dng oluřturup geriye dođru bilgi aktarıyor ise geri beslemeli yapay sinir ađları olarak isimlendirilmektedir. İleri beslemeli yapay sinir ađları, geri beslemeli versiyonlarına gre hızlı alıřırlar ve abuk sonu retirler. Geri beslemeli yapay sinir ađlarında ise iřlem yapan elemanlar ıkan veriyi dng oluřturacak řekilde tekrar giriře aktarabilirler ya da yeni bir veri giriři alabilirler. Bu durumda iřlem sresi uzar ve yapay sinir ađının sonu retmesi ve eđitilmesi grece yavař olur.

### **3.1.3.1. Girdi Katmanı**

Girdi katmanı yapay sinir ađlarının dıř dnyadan veri aldıkları katmanlardır. Bu katman ierisinde girdi nronları yer alır ve n adet olabilir. Aynı zamanda bir nron n adet giriře ancak sadece bir adet ıkıřı sahip olabilir [61]. Girdi katmanında yer alan girdi nronlarına veri, yapay sinir ađı dıřından gelir ve ađırlıklardan oluřan bađlantılar aracılıđı ile arpılarak gizli katmana iřlenme amacıyla iletilir.

### **3.1.3.2. Ađırlıklar**

Ađırlıklar girdi katmanı ile gizli katmanlar arasında bulunurlar ve girdi verisinin ađ zerindeki etkisini belirlerler. Ađırlıkların pozitif ya da negatif olması muhtemeldir ve bu durum ilgili giriřin nemi zerinde etkili deđildir. Negatif bir ađırlık da en az pozitif bir ađırlık kadar nemlidir. Ađırlıkların bir diđer zelliđi ise sabit ya da deđiřken deđerler alabilmesidir.

### **3.1.3.3. Gizli Katman**

Gizli ya da ara katmanlar girdi katmanı ile ıktı katmanı arasında yer alırlar ve girdi katmanından gnderilen ađırlıklandırılmıř verilerin iřlenerek ıktı katmanına iletilmesini sađlarlar. Basit yapay sinir ađında giriř ile ıkıř katmanı tek iken gizli katman sayısı birden fazla olabilir. Gizli katmanların sayısının fazla ya da az olması yapay sinir ađının kompleks ya da basit bir yapıya sahip olması anlamına gelir ve

doğrudan ağıın çalışma süresini etkiler. Gizli katmanların çokluğu yapay sinir ağıının ezberlemesini engelleyebileceği gibi ağıın yapısının veri setine çok fazla adapte olmasını sağlayacağıından dolayı yeni veriler karşısındaki değerlendirme yeteneğini olumsuz olarak etkileyebilir. Gizli katman sayısı düşükten başlanılarak test sonuçlarının incelenmesi ile değerlendirilip ayarlanabilir [61].

#### 3.1.3.4. Birleştirme Fonksiyonu

Yapay sinir ağlarında yer alan hesaplama hücresidir ve net girdiyi hesaplamak amacıyla kullanılır. Literatürde birkaç farklı birleştirme fonksiyonu vardır. Temelde diğer yapay sinir hücrelerinden gelen sinyalleri alır ve ağırlıklar ile bu sinyalleri ağırlıklandırır. Daha sonra ilgili birleştirme fonksiyonunu kullanarak veri dönüşümünü gerçekleştirir ve çıktı olarak diğer yapay sinir hücrelerine gönderir. Birleştirme fonksiyonları ve formülleri takip eden eşitliklerde verildiği gibidir [60,61].

Toplam birleştirme fonksiyonu;

$$Net\ Girdi = \sum_i^n X_i W_i \quad (3.1)$$

Toplam birleştirme fonksiyonunda her bir girdi kendi ağırlığı ile çarpılır ve bu çarpımın sonuçları kümülatif olarak toplanır.

Çarpım birleştirme fonksiyonu;

$$Net\ Girdi = \prod_i^n X_i W_i \quad (3.2)$$

Çarpım birleştirme fonksiyonu girdiler ile ilgili girdilere ait ağırlıkları birbirleri ile çarpır ve her bir girdi-ağırlık ikilisi diğer girdi-ağırlıklar ile çarpılır.

Maksimum birleştirme fonksiyonu;

$$Net\ Girdi = Max(X_i W_i) \quad (3.3)$$



Maksimum birleştirme fonksiyonunda tüm girdiler ile ağırlıkları çarpılır ve diğer girdi-ağırlık çarpımları ile kıyaslanarak en büyük girdi-ağırlık çarpımı net girdi olarak alınır.

Minimum birleştirme fonksiyonu;

$$Net\ Girdi = Min(X_i W_i) \quad (3.4)$$

Minimum birleştirme fonksiyonunda tüm girdiler ile ağırlıkları çarpılır ve diğer girdi-ağırlık çarpımları ile kıyaslanarak en küçük girdi-ağırlık çarpımı net girdi olarak alınır.

Çoğunluk birleştirme fonksiyonu;

$$Net\ Girdi = \sum_i sgn(X_i W_i) \quad (3.5)$$

Çoğunluk birleştirme fonksiyonunda tüm girdiler ile ağırlıkları çarpılır ve bu çarpımların işaret fonksiyonları göz önünde bulundurularak girdi-ağırlık çarpımları toplanır. Büyük olan işaret fonksiyonu toplamı net girdi kabul edilir.

Kümülatif toplam birleştirme fonksiyonu;

$$Net\ Girdi = Net_{eski} + \sum_i^n X_i W_i \quad (3.6)$$

Çoğunluk birleştirme fonksiyonunda her girdi ile kendisine ait ağırlık çarpılarak toplanır ve bir önceki net girdi üzerine eklenir.

Burada uygulanan tüm birleştirme fonksiyonları n adet girdi ve ağırlık için gerçekleştirilir. Ağırlık sayısı girdi sayısına eşit olmak zorundadır.

$X_i$ ; yapay sinir hücresine gelen  $i$ . girdi

$W_i$ ;  $i$ . girdi için atanan ağırlık değeri


n; girdi ve ağırlık sayısı

### 3.1.3.5. Transfer Fonksiyonu

Transfer fonksiyonu birleştirme fonksiyonunda gelen net girdiyi işleyen ve buna karşı bir tepki oluşturan fonksiyondur. Girdi ile çıktı verisi arasında bir benzerlik olmaması adına doğrusal olmayan fonksiyonların kullanılması tercih edilse de bazı problemler için doğrusal transfer fonksiyonu kullanılabilir. Transfer fonksiyonları en basit ifade ile çıktıyı sınırlandırmak için kullanılırlar. Transfer fonksiyonları da birleştirme fonksiyonları gibi çeşitliliğe sahiptir. Literatürde en sık kullanılan transfer fonksiyonları takip eden eşitliklerde verilmiştir.

Doğrusal fonksiyon; transfer fonksiyonuna gelen net girdi  $\alpha$  sayısı ile çarpılarak çıktı elde edilir (Şekil 3.4).


$$f(net) = net \times \alpha \quad (3.7)$$



Şekil 3.4. Doğrusal transfer fonksiyonu [61].

Basamak fonksiyonu; transfer fonksiyonuna gelen net girdi belirlenen limitin üzerinde ya da altındaysa 1 ve 0 değerlerinden birisini alabilir (Şekil 3.5).


$$f(net) = \begin{cases} 0 & \text{eğer } net \leq \text{eşik} \\ 1 & \text{eğer } net > \text{eşik} \end{cases} \quad (3.8)$$



Şekil 3.5. Basamak transfer fonksiyonu [61].

Aralık fonksiyonu; transfer fonksiyonuna gelen net girdi belirlenen sınırlar arasında ise kendisi üzerinde ya da altındaysa 1 ve 0 değerlerinden birisini alabilir (Şekil 3.6) [59].


$$f(net) = \begin{cases} 0, & net \leq \text{alt sınır} \\ m * net + n, & \text{alt sınır} \leq net \leq \text{üst sınır} \\ 1, & net > \text{üst sınır} \end{cases} \quad (3.9)$$



Şekil 3.6. Aralık transfer fonksiyonu [61].

Hiperbolik tanjant fonksiyonu; transfer fonksiyonuna gelen net girdiye tanjant fonksiyonu uygulanarak çıktı elde edilir (Şekil 3.7).


$$f(net) = \frac{e^{net} - e^{-net}}{e^{net} + e^{-net}} \quad (3.10)$$



Şekil 3.7. Hiperbolik tanjant transfer fonksiyonu [61].

Sigmoid fonksiyonu yapay sinir ağları uygulamalarında en çok tercih edilen transfer fonksiyonudur. Sürekli artan bir fonksiyondur ve doğrusal olmayan problemler için kullanıldığı gibi doğrusal olanlar içinde başarılı bir şekilde çalışır. Fonksiyon çıktısı 0 ile 1 arasında bir değer olur (Şekil 3.8).

$$f(net) = \frac{1}{1+e^{-net}} \quad (3.11)$$



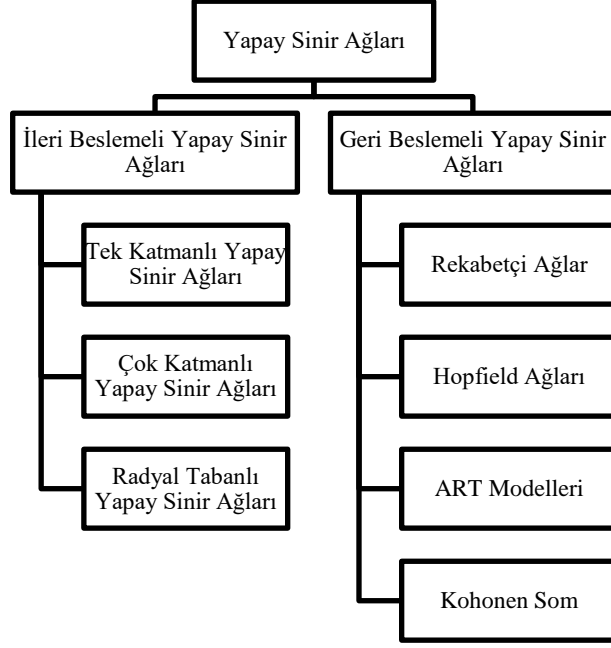
Şekil 3.8. Sigmoid transfer fonksiyonu [61].

### 3.1.3.6. Çıktı Katmanı

Çıktı katmanı transfer fonksiyonun uygulanması sonucu elde edilen çıktıların bulunduğu katmandır. Bu katmanda elde edilen bilgiler yapay sinir ağının girdi katmanında verilen girdilere karşı yapay sinir ağının verdiği tepkidir [58].

### 3.1.4. Yapay Sinir Ağı Mimarileri

Yapay sinir ağları birçok yapay sinir hücresinin bir araya gelmesinden oluşan ağlardır ve katmanlara ayrılmışlardır. Yapay sinir ağı mimarileri yapay sinir hücreleri arasındaki iletişimin yönüne göre sınıflandırılmaktadırlar. Literatürde ileri beslemeli yapay sinir ağları ve geri beslemeli yapay sinir ağları olmak üzere iki çeşit sınıflandırma mevcuttur. Yapay sinir hücreleri arasındaki bu iletişimin yönü girdi katmanından çıktı katmanına doğru tek yönde ise bu tür ağlara ileri beslemeli yapay sinir ağları denilmektedir. Eğer yapay sinir hücreleri arasında bir döngü söz konusu ise bu tarz yapay sinir ağlarına ise geri beslemeli yapay sinir ağları denilmektedir [59]. Şekil 3.9'da YSA mimarileri gösterilmiştir.



Şekil 3.9. Yapay sinir ağları mimarisi.

#### 3.1.4.1. İleri Beslemeli Yapay Sinir Ağları


İleri beslemeli yapay sinir ağlarında girdiler, katmanlar halinde sınıflandırılan hücrelerden tek yönlü olarak çıktı katmanına doğru akarlar. Yapay sinir hücreleri arasındaki iletişim, giriş bilgilerinin akışının tek bir doğrultuda olacak şekilde dizayn edilmiştir. İleri beslemeli yapay sinir ağlarında her bir katmandaki yapay sinir hücreleri bir sonraki katmanda bulunan yapay sinir hücreleri ile iletişim içerisindedirler fakat kendi katmanında bulunan diğer yapay sinir hücreleri ile aralarında bir ilişki yoktur.

İleri beslemeli basit bir yapay sinir ağı girdi katmanından aldığı veriyi gizli katmana iletir. Burada işlem gören veri varsa diğer gizli katmanlara iletilir ve son olarak çıktı katmanına iletilerek yapay sinir ağının çıktısı elde edilir ve bu veri akışı sırasında herhangi bir geri besleme yoktur.

Yapay sinir ağının ağırlıklarının güncellenebilmesi ve öğrenme işleminin gerçekleşebilmesi için elde edilen çıktı, beklenen çıktı değeri ile karşılaştırılarak bir

hata verisi oluşturulur ve bu hata verisi yapay sinir ağının ağırlıklarının güncellenmesi için kullanılır.

Yapay sinir ağları arasında en basit mimariye sahip ağlardan biri tek katmanlı yapay sinir ağlarıdır. Tek katmanlı birkaç yapay sinir ağının bir araya gelmesi ile çok katmanlı yapay sinir ağları oluşturulur. Şekil 3.10'da basit bir ileri beslemeli yapay sinir ağı mimarisi verilmiştir.



Şekil 3.10. İleri beslemeli yapay sinir ağları mimarisi.

#### 3.1.4.1.1. Tek Katmanlı Yapay Sinir Ağları

Tek katmanlı yapay sinir ağları sadece girdi ve çıktı katmanından oluşan ve doğrusal olan problemler için tercih edilen yapay sinir ağı mimarilerindedir. Her bir katman bir ya da daha fazla yapay sinir hücresine sahip olabilir. Bu tarz mimarilerde sınır değeri yapay sinir hücrelerinin ve yapay sinir ağının çıktısının 0 olmasını önlemek amacıyla kullanılır ve değeri her zaman 1 olarak alınır. Tek katmanlı yapay sinir ağı için çıktı fonksiyonu eşitlik 3.12'de verilmiştir [58].

$$\text{Çıktı} = f(\sum_{i=1}^n W_i X_i + \emptyset) \quad (3.12)$$

Eşitlik 3.12'de  $X$  değerleri tek katmanlı yapay sinir ağının girdisini ve  $W$  değeri ise ilgili girdiye ait ağırlıkları temsil etmektedir.  $\emptyset$  ise sınır değeridir.

### 3.1.4.1.2. Çok Katmanlı Yapay Sinir Ağları

Çok katmanlı yapay sinir ağları ileri yönlü beslemeye sahip yapay sinir ağları arasında yaygın olarak kullanılan yapay sinir ağı mimarisidir. Yapay sinir hücreleri bu tarz mimarilerde katmanlar arasında daima ileriye veri akışı sağlayacak şekilde ilişkilendirilmişlerdir. Tek katmanlı yapay sinir ağlarının bir araya gelmesi ile oluşturulabilirler.

### 3.1.4.1.3. Radyal Tabanlı Yapay Sinir Ağları

Radyal tabanlı yapay sinir ağları, yapay sinir ağlarında filtreleme problemi için kullanılmış ve insan sinir hücrelerinin hali hazırdaki durumu değiştirme tutumundan benzetilmişlerdir. Radyal tabanlı yapay sinir ağlarının mimarisi normal yapay sinir ağlarında olduğu gibi girdi katmanı, gizli katman ve çıktı katmanı olmak üzere üç katmandan oluşan bir mimaridir. Fakat birçok yapay sinir ağında veriler girdi katmanından gizli katmana geçerken herhangi bir işleme maruz kalmazlar. Radyal tabanlı yapay sinir ağlarında ise veriler gizli katmana geçişleri sırasında eğrisel kümeleme ve radyal tabanlı hareket planlama analizine maruz kalırlar. Gizli katmandan çıkış katmanına iletilme aşamasında ise veriler diğer yapay sinir ağı mimarilerinde olduğu gibi işlem görmeye devam eder.

Radyal tabanlı yapay sinir ağlarının formülasyonu eşitlik 3.13'te verilmiştir.

$$\text{Çıktı}(y) = \sum_{j=1}^N W_{ij} \phi_j(x, c_j) = \sum_{j=1}^N W_{ij} \phi_j(\|x - c_j\|_2), \quad i = 1, 2, \dots, m \quad (3.13)$$

Burada;

$x$ ; yapay sinir ağının girdi vektörü

$W_{ij}$ ; yapay sinir ağının çıktı katmanında yer alan ağırlıklar

$\phi_j$ ; radyal temelli transfer fonksiyonu

$c_j$ ; yapay sinir ağı girdi alt setine ait radyal temelli merkezler


$\| \cdot \|$ ; Öklid ifadesi

$N$ ; yapay sinir ağının gizli katmanında bulunan yapay sinir hücresi sayısı

### 3.1.4.2. Geri Beslemeli Yapay Sinir Ağları

Geri beslemeli yapay sinir ağları mimarileri gereği en az bir yapay sinir hücresinde olmak üzere, yapay sinir hücresinin çıkışı, kendisinin veya başka bir yapay sinir hücresinin girişi olabilecek şekilde tasarlanmışlardır. Geri besleme işlemi bu tip mimarilerde geciktirme ara elemanları aracılığı ile yapılmaktadır. Geri besleme işlemi katmanlar arası ya da aynı katman içerisinde yer alan yapay sinir hücreleri arasında olabilir ve yapay sinir ağını doğrusal olmayan bir yapıda şekillendirirler.

Klasik geri besleme akışı iki aşamadan oluşur. Bu aşamalar yayılma ve uyum gösterme olarak ifade edilmektedir. Geri yayılım algoritmasının temel amacı yapay sinir ağı sonucunda elde edilen çıktı ile arzu edilen çıktı arasındaki farkı tespit edip yapay sinir hücrelerine bu farkı girdi olarak vermek ve sonucunda bir düzeltme işlemi uygulayarak hatayı kabul edilebilir bir seviyeye getirmektedir. Veri bilgisi ağ boyunca ileriye doğru akarken, hata düzeltme bilgisi ise geriye doğru akmaktadır [58,60,61]. Şekil 3.11’de geri beslemeli ağ mimarisi gösterilmiştir.



Şekil 3.11. Geri beslemeli yapay sinir ağları mimarisi.

Geri yayılım algoritmasının çalışma mantığı en küçük kareler yöntemi ile aynıdır. Gerçek çıktı ile arzu edilen çıktı arasındaki farkı azaltmak amacıyla girdi olarak yapay sinir hücrelerine ileten bir algoritmadır. İletilen bu hata bilgisi ile yapay sinir



ağı kullandığı ağırlıkları güncelleyerek hatayı minimize etmeye çalışır ve bir nevi öğrenme işlemi gerçekleştirir.

Yeni öğrenmeye başlayan bir yapay sinir ağına ağırlıklar rastgele atanır ve verilen girişlere göre yapay sinir ağı öğrenme işlemine başlar. Çıkış değeri elde edildikten sonra veri setinde olması gereken çıkış değeri ile kıyaslanır ve ortaya çıkan hata hesaplanarak ağırlıkların güncellenmesi beklenir. Geri yayılım algoritmasına ait eşitlikler aşağıdaki gibi verilmiştir [59].

$$net_i = \sum_i^n W_i X_i \quad (3.14)$$

$$f(net_i) = \frac{1}{1+e^{-(net_i+\beta_i)}} \quad (3.15)$$

Sigmoid transfer fonksiyonu türevi alınabilen bir fonksiyon olduğu için kullanılmıştır. Türevi alınan başka bir fonksiyon da kullanılabilir.

$$E_i = d_i - O_i \quad (3.16)$$

$E_i$  fark değeri arzu edilen değer ile yapay sinir ağının verdiği değer farkı alınarak elde edilir. Elde edilen fark değerinin yönünün belirlenebilmesi için eşitlik 3.17 kullanılır.

$$\delta_i = f'(net_i) \times E_i \quad (3.17)$$

Eşitlik 3.18 ile yapay sinir ağında yer alan ağırlıkların ne kadar değişeceği hesaplanır. Eşitlik 3.19 ile ise yeni ağırlık değerleri hesaplanır.

$$\Delta W_{j,i}(t) = \lambda * \delta_i * O_i + \alpha * \Delta W_{j,i}(t - 1) \quad (3.18)$$

$$W_{j,i}(t) = W_{j,i}(t - 1) + \Delta W_{j,i}(t) \quad (3.19)$$

Geri yayılım algoritmasının dezavantajı ise bu işlemlerin büyük bir yapıya sahip yapay sinir ağlarında çok fazla zaman almasıdır.

#### **3.1.4.2.1. Hopfield Geri Beslemeli Yapay Sinir Ağları**

Hopfield ağları özellikleri sayesinde koşutlu çalışan ağlarda işlem yapabilen ağlardır. Genel kullanım alanları görüntü ya da sinyal işleme uygulamalarında yaşanan optimizasyon problemini ortadan kaldırmaktır.

Hopfield geri beslemeli yapay sinir ağlarında kullanılan yapay sinir hücresi transfer fonksiyonu eşitlik 3.20'de verilmiştir [58]. Hopfield geri beslemeli yapay sinir ağları bazı uygulamalarda global çözümler yerine lokal çözümlerde takılı kalabilmekte ve bu durum yapay sinir ağının çalışmasını olumsuz etkilemektedir.

$$V = f(U) = \frac{1}{2} \left(1 + \tanh \frac{U}{U_0}\right) \quad (3.20)$$

$U$  ilgili sinyale ya da görüntüye ait giriş sinyali ve  $V$  ise çıkış sinyalini temsil etmektedir.  $U_0$  ise eşitlik sabitidir.

#### **3.1.4.2.2. ART Geri Beslemeli Yapay Sinir Ağları**

ART ya da tam adıyla uyarlanabilir titreşim teorisi (adaptif rezonans teorisi) geri beslemeli yapay sinir ağları, gerçek zamanlı uygulamalarda kullanılan yapay sinir ağı mimarilerindedir. Öğrenme, tanıma, arama, tahmin, hipotez testi gibi çalışmalar için başvurulabilir.

#### **3.1.4.2.3. Kohonen Som Geri Beslemeli Yapay Sinir Ağları**

Som geri beslemeli yapay sinir ağı mimarisi Kohonen tarafından geliştirilmiştir. Örüntü tanıma alanında kullanılabilen denetimsiz öğrenme yapabilen bir yapay sinir ağı mimarisidir. Verilerin girişteki görünümü yapay sinir ağı çıkışında da korunabildiği için sınıflandırma süreçlerinde başarılı bir ağıdır.

Bu mimariye sahip yapay sinir ağlarında giriş katmanı bir adettir ve n adet girişi iki boyut olarak eşleştiren Kohonen katmanına sahiptir. Rekabetçi bir yapay sinir ağı olduğu için yapay sinir hücrelerinin çıkışına göre kazanan ve kaybeden yapay sinir hücrelerini değerlendirmek için eşitlik 3.21 ve 3.22 kullanılır [58]. Burada, q kazanan düğümü s ise algoritmanın adımını ifade ederken,  $\alpha^s$  ise s. adım için öğrenme oranını ifade etmektedir.

$$W_q^{s+1} = W_q^s(1 - \alpha^s) + X_i\alpha^s \quad (3.21)$$

$$W_l^{s+1} = W_l^s \quad (3.22)$$

### 3.1.5. Yapay Sinir Ağı Öğrenme Algoritmaları

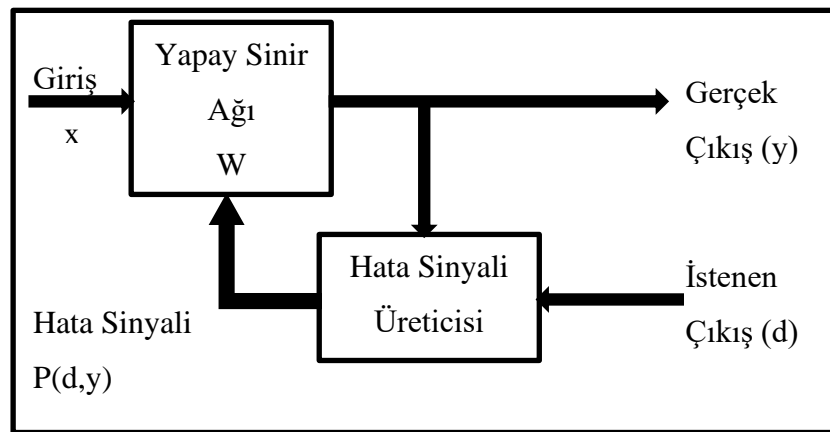
Yapay sinir ağlarının günümüzde bu denli yaygın kullanılmasının başlıca nedenlerinden biri öğrenebilme yeteneğidir. Klasik yöntemlerin aksine belirli bir algoritmayı iterasyonlar şeklinde sonuçlara ulaştırmak üzere takip etmezler, insanlarda olduğu gibi tecrübeye sahiptirler. Tecrübe öğrenme sürecinin bir sonucudur. Öğrenme işlemini de ilgili problemler için tanımlanan veri setleri aracılığı ile veriler arasında ilişki kurarak gerçekleştirirler. İlişki kurma süreci ise yapay sinir ağının yapay sinir hücreleri üzerinde sahip olduğu ağırlıklar üzerinden gerçekleştirilir. Bu ağırlıkların evrilmesi sonucu öğrenme gerçekleşmiş olur. Ağırlıkların evrilmesi ya da değiştirilmesi yapay sinir ağında kullanılan öğrenme kurallarına göre değişiklik gösterebilir. Literatürde yapay sinir ağları için yer alan öğrenme algoritmaları danışmanlı, danışmansız ve takviyeli olmak üzere üç temel gruba indirgenmiştir [59]. Bu üç grup haricinde melez yöntemler kullanan bazı öğrenme yöntemleri de geliştirilmiştir. Bunlar olasılık temelli yapay sinir ağları (PBNN) ya da radyal temelli yapay sinir ağlarında (RBNN) kullanılmaktadır [60].

Hebbian öğrenme kuralı yapay sinir ağlarının öğrenme mantığını açıklayan çok basit bir kuraldır ve tüm öğrenme kurallarının temelini oluşturur. Hebbian öğrenme kuralına göre iki yapay sinir hücresi aynı anda aktif ise bu iki yapay sinir hücresi birbirleri ile ilişkilidir ve aralarındaki bağlantı güçlü olmalıdır [60].

Yapay sinir ağıları da insanlar gibi bir öğrenme sürecine sahiptir. Dışarıdan alınan sinyaller insan beyni içerisinde işlenerek bir tepki üretilir ve bu tepki dışarıya aktarılır. Aktarılan tepki yanlış bir tepki ise beyin bu tepkiyi doğru bir hale getirmek için veri işleme aşamasında değişiklik yapar. Bu süreç sonucunda beyin artık nasıl tepki vereceğini öğrenmiş olur ve bu tepkiyi kaydederek tecrübeyi oluşturur. İnsan beyni tecrübe etmediği olaylar karşısında doğaçlama olarak bir tepki üretir ve bu durum onu tecrübesiz kılar. Yapay sinir ağıları da dışarıdan aldığı veriyi birleştirme ve transfer fonksiyonlarından geçirerek çıktı üretir. Bu çıktı, geçmiş tecrübeleri ile karşılaştırılarak hata hesaplanır ve yapay sinir ağına doğru çıktıyı vermesi sağlanır. Bu öğrenme süreci yapay sinir ağına ağırlıklarının değiştirilmesi sonucu olur ve bu ağırlıklar tepkilerin kaydedildiği tecrübe olarak nitelendirilebilir. Yapay sinir ağlarının doğru tepkileri vermesi için tekrarlanan bu sürece epoch adı verilir. Epoch sayısının fazla olması yapay sinir ağına yavaş öğrenmesi anlamına gelebilir ve performansını düşürür [60].

### 3.1.5.1. Danışmanlı Öğrenme

Yapay sinir ağına öğrenme aşamasında verilen girdilere karşılık istenen çıktı değerleri belirtiliyor ise bu öğrenme tipine danışmanlı öğrenme ya da aktif öğrenme denir. Şekil 3.12’de danışmanlı öğrenme yapısı gösterilmiştir.



Şekil 3.12. Danışmanlı öğrenme.

Yapay sinir ağı elinde olan arzu edilen çıkış değerine karşılık hesapladığı çıkış değerini karşılaştırır ve elde ettiği hata bilgisine göre yapay sinir hücrelerinin ağırlıklarını günceller. Eğer hata kabul edilir bir seviyeye geldiyse ağırlıkların değiştirilmesi işlemi ve dolayısıyla öğrenme son bulur.

Danışmanlı öğrenme algoritmalarında yeterli sayıda eğitim verisi var ise başarılı sonuçlar elde edilebilir. Yapay zeka uygulamalarının bir çoğunda danışmanlı öğrenme yöntemi kullanılmaktadır. Bu yöntemin uygulandığı problemlerde genellikle problemin sonucu ya da benzer problemlerin sonucu bilinmektedir ve bu tarz problemler insanlar tarafından çözülebilecek problemlerdir.

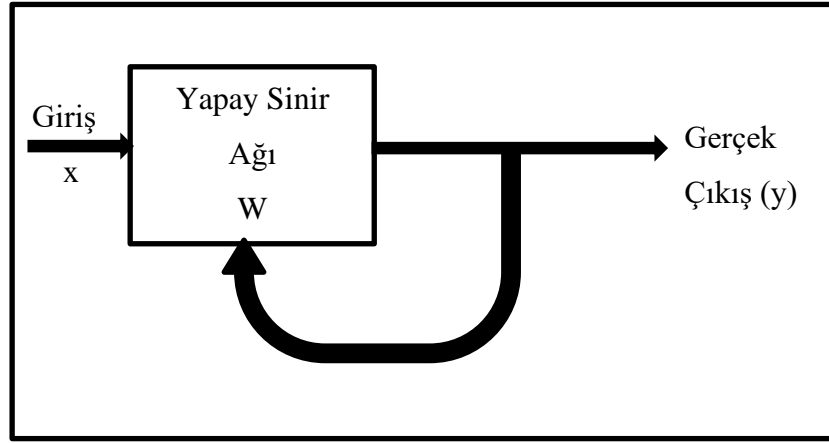
Danışmanlı öğrenme yöntemi kullanılan yapay zeka çalışmalarında yapay sinir ağı kullanılmadan önce mutlaka eğitilmelidir. Eğitim seti doğrudan yapay sinir ağı performansı üzerinde etkilidir.

Literatürde en çok karşılaşılan danışmanlı öğrenme yöntemleri delta kuralı, geri yayılma algoritması, genelleştirilmiş delta kuralı ve vektör kuantalama modeli (LVQ) algoritmasıdır. İleri beslemeli yapay sinir ağı mimarilerinden olan çok katmanlı yapay sinir ağları ve radyal taban fonksiyonlu yapay sinir ağları danışmanlı öğrenmeyi kullanan mimarilerdir [58].

### **3.1.5.2. Danışmansız Öğrenme**

Yapay sinir ağının öğrenme aşamasında verilen girdilere karşılık istenen çıktı değerleri belirtilmiyor ise bu öğrenme tipine danışmansız öğrenme denir. Bu tip öğrenmede giriş verileri aynı zamanda çıkış verileridir. Yapay sinir ağının öğrenmesine yardım eden bir parametre yoktur. Girdi katmanına verilen veri seti içerisindeki ilişkilerin yapay sinir ağı tarafından kendiliğinden öğrenmesi hedeflenir. Bu tür yapay sinir ağlarının sonuçlarının bir operatör tarafından değerlendirilmesi gerekir. Danışmansız öğrenme ile çalışan yapay sinir ağlarında sonuç olarak birbirlerine benzeyen giriş verilerinin kümelenmesi elde edilir.

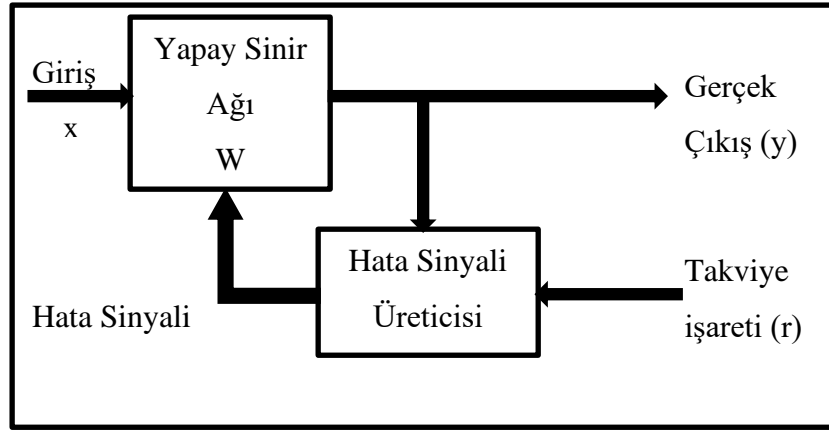
Kohonen Som geri beslemeli yapay sinir ağı ya da uyarlanabilir titreşim teorisi gibi kompetitif yapay sinir ağları danışmansız öğrenme kullanan mimarilerdir. Bu tarz öğrenme yöntemleri kümeleme, sınıflandırma, ayırma, süzme gibi uygulamalar için kullanılabilir [58]. Çıktı bilgisi olmadığı için yapay sinir ağının ağırlığı kümeleme ya da gruplandırma için değiştirilerek öğrenme gerçekleştirilir. Şekil 3.13'te danışmansız öğrenme yapısı gösterilmiştir.



Şekil 3.13. Danışmansız öğrenme.

### 3.1.5.3. Takviyeli Öğrenme

Takviyeli öğrenme danışmanlı öğrenmeye oldukça benzerdir. Danışmanlı öğrenmede yapay sinir ağının çıktısının ne olması gerektiği belirtilirken takviyeli öğrenmede ise yapay sinir ağının verdiği çıktının doğruluğuna bir derece atanır. Bu nedenle bazı kaynaklarda danışmanlı öğrenmenin özel bir versiyonu olarak nitelendirilirler. Genetik algoritmalar ve LVQ (vektör kuantalama modeli) takviyeli öğrenme yöntemini kullanırlar ve sonuç değerlerini bir uygunluk değerine göre kıyaslayarak iterasyonlarına devam ederler. Takviyeli öğrenme yöntemi kullanan yapay sinir ağları da eğiticiden gelen sinyal doğrultusunda ağırlıkları değiştirerek öğrenme işlemini gerçekleştirir. Şekil 3.14'te takviyeli öğrenme yapısı gösterilmiştir.



Şekil 3.14. Takviyeli öğrenme.

### 3.1.6. Yapay Sinir Ağı Öğrenme Kuralları

Yapay sinir ağlarında öğrenme işlemini gerçekleştirebilmek için birçok algoritma bulunmaktadır ve bu algoritmalar bazı öğrenme kurallarına bağlı olarak çalışırlar.

#### 3.1.6.1. Hebb Öğrenme Kuralı

Literatürde en çok kullanılan ve bilinen öğrenme kuralıdır. Temelde yapay sinir ağının ilişki sayısı değiştirilirse, öğrenme işleminin gerçekleştirilebileceğini belirtir. Hebb öğrenme kuralı, Hebb'in 1949 yılında yayınladığı Davranış Organizasyonu kitabında ilk defa dile getirilmiştir.


Hebb öğrenme kuralına göre aynı anda iki yapay sinir hücresi aktif ve iletişim halindeyse ve matematiksel olarak aynı işarete sahipse bu iki yapay sinir hücresi arasında yüksek ilişki olması beklenir ve bu durumda yapay sinir ağı ağırlıklarını değiştirerek öğrenme işlemini gerçekleştirir [58,60,61].

#### 3.1.6.2. Hopfield Öğrenme Kuralı

Temelde Hebb kuralı ile aynı prensipte çalışır. Hebb kuralında iki yapay sinir hücresi arasındaki ilişki aynı anda aktif ya da pasif ise aralarındaki ağırlık artırılır değil ise azaltılır, Hopfield öğrenme kuralı ise ağırlığın ne kadar arttırılacağı ya da azaltılacağı

öğrenme katsayısı ile belirlenir. Öğrenme katsayısı 0 ile 1 arasında kullanıcı tarafından belirlenir ve sabittir.

Hopfield öğrenme kuralı kullanan bir yapay sinir ağı tek katmanlıdır ve geri yayımlı bir ağıdır. Tüm yapay sinir hücreleri girdi ve çıktı elemanları olarak işlem görmektedir. Şekil 3.15'te Hopfield öğrenme kuralı kullanan bir ağ verilmiştir.



Şekil 3.15. Hopfield öğrenme kuralı [60].

### 3.1.6.3. Kohonen Öğrenme Kuralı

Kohonen kuralı yarışmacı yapay sinir ağları için kullanılan bir kuraldır ve bu kurala göre yapay sinir ağında ağırlıkların ayarlanması için, yapay sinir hücreleri birbirleri ile yarışır. Bu kurallara göre en iyi çıktıyı veren yapay sinir hücresinin ağırlığı değişir, diğer yapay sinir hücrelerinin ağırlığı ise aynı bırakılır. Ama kazanan yapay sinir hücresi kendisine komşu yapay sinir hücrelerinin de ağırlıklarını arttırabilir böylece bir sonraki epocs için kazanma şansını da arttırmış olur. Kohonen öğrenme kuralı bu özelliği ile Hebb kuralından farklılaşır. Kohonen öğrenme kuralı biyolojik sistemlerden benzetilmiştir [58].

Kompetitiv yapay sinir ağları için kullanıldığından dolayı Kohonen öğrenme kuralı danışmansız olarak öğrenme işlemini gerçekleştirebilir. Yapay sinir ağı gruplandırma işlemini yapabilmek için veri setini nasıl kullanacağına kendisi karar verir [60].



### 3.1.6.4. Delta Öğrenme Kuralı

Delta öğrenme kuralı aynı Hebb kuralında olduğu gibi arzu edilen çıktı değeri ile yapay sinir ağının verdiği çıktı değerini karşılaştırarak arasındaki farkı azaltmak amacıyla geri besleme yapan bir öğrenme kuralıdır. Arzu edilen ile yapay sinir ağının verdiği çıktı arasındaki hataların karesini minimum seviyeye ya da kabul edilebilir seviyeye indirmeye çalışır.

Hebb öğrenme kuralından farklı olarak delta öğrenme kuralında, hesaplanan hata oranı transfer fonksiyonunun türevi ile dönüştürüldükten sonra son katmandan ilk katmana doğru olacak şekilde son iki ardışık katmanda bulunan yapay sinir hücrelerinin ağırlıklarına dağıtılır. Bir başka ifade ile hesaplanan hata önceki katmanlara tek seferde geri yayılır. Bu işlem silsile halinde ilk katmana ulaşılan kadar devam eder [58]. Delta öğrenme kuralı hem ileri yayılımlı hem de geri yayılımlı yapay sinir ağlarında kullanılabilir.

## 3.2. DESTEK VEKTÖR MAKİNELERİ

Destek vektör makineleri en basit anlamda istatistiksel teorileri baz alan bir makine öğrenme tekniğidir. Bugün sınıflandırma/kümeleme, regresyon, karakter tanıma ve zaman serileri gibi alanlarda kullanılabilir. Vapnik tarafından 1992’te sınıflandırma problemleri için ortaya atılmıştır. 1995 yılında Cortes ve Vapnik tarafından bugün kullanılan haline getirilmiştir. Daha sonraları 1997 yılında yine Vapnik ve arkadaşları tarafından geliştirilerek regresyon problemlerine de uyarlanmıştır [62]. Diğer makine öğrenmesi yöntemlerinden farklı olarak yapısal riskin minimizasyonuna odaklanır. Bu nedenle diğer makine öğrenmesi yöntemleri gibi çok sayıda veriye gereksinim duymaz, yerel optimum çözüme takılı kalmaz, fazla ya da eksik uyum sağlamaz [63].

İlk kullanım amacı sınıflandırma olan bu teknik sonraki zamanlarda regresyon ve zaman serileri modellerinde denenmiş ve alınan başarılı sonuçlar sayesinde bu alanlarda da yaygınlaşmıştır [62].

DVM'nin regresyon yöntemindeki çalışma prensibi, eğitim verisinin gerçeğe en yakın imajını oluşturan, istatistiksel öğrenme teorisi ile uyumlu doğrusal bir ayırıcı fonksiyon bulunmasıdır. Doğrusal olmayan veri setlerinde ise kernel/çekirdek fonksiyonları kullanılmaktadır [64]. Makine öğrenmesi sürecinde, istatistiksel öğrenme teorisine bağlı olarak gerçek riske benzer ampirik bir risk oluşmaktadır. İstatistiksel öğrenme teorisi, destek vektör makinesinin öğrenme yetisi ile ampirik risk arasında denge kurmaya çalışır ve böylece iyi bir genelleme yapabilir. Buradaki temel kabul eğitim setinde yer alan tüm verilerin bağımsız ve benzer şekilde dağıldığıdır. Tüm algoritalarda olduğu gibi destek vektör makinelerinde de bazı veriler yanlış sınıflandırılabilir [65].

Destek vektör makineleri aslında istatistik ve yapay sinir ağları tekniklerinin bir hibrit versiyonudur. Kullanılan sigmoid kernel fonksiyonu sebebi ile temelde iki katmanlı ileri beslemeli bir sinir ağıdır. Verileri en uygun şekilde ikiye böler [64,65]. İstatistiksel bir karşılaştırma yerine, verilerin ayırım marjını geometrik bir değerlendirme kriteri ile minimize etmeye çalıştığı için iyi bir performansa sahiptir. Yani sınıflandırılan verinin istatistiksel dağılımı ile ilgilenmez. Yaygınlaşmasının en önemli nedenleri, diğer sınıflandırma yöntemlerine göre daha başarılı sonuçlar vermesi, çalışmak için az sayıda parametreye ihtiyaç duyması ve öğrenme problemini aşmak için kuadratik programlama kullanmasıdır. Konveks bir kuadratik programlama kullandığı için elde edilen minimum çözümlerin tamamı globaldir. Temelde iki katmanlı bir yapay sinir ağına benzese de iki yöntem kıyaslandığında, destek vektör makineleri yapay sinir ağlarına göre yerel çözümlerden kaçabilmekte ve daha başarılı bir genelleme yapabilmektedir [65].

Destek vektör makineleri ortaya atıldığı zaman doğrusal problemlerden oluşturulmuştur. Fakat yöntem çalışma prensibinin getirdiği avantaj ile birlikte makinenin ya da vektörlerin eğitiminde, eğitim verisinin iç çarpım hesaplamalarını dikkate aldığı için kernel fonksiyonlarını değiştirerek doğrusal olmayan problemlere de uyarlanabilmektedir. Basit bir dil ile ifade edersek, doğrusal olmayan bir girdi setini kernel fonksiyonu yardımı ile doğrusal bir girdiye dönüştürmektedir. Sonrasında bu girdiyi doğrusal bir problem gibi çözmektedir. Bu nedenle doğrusal olmayan regresyon problemlerinde mükemmel sonuçlar vermekteler [65].

Yapılan çalışmalarda destek vektör makineleri, yapay sinir ağları, karar ağaçları, k-ortalamları gibi diğer yapay zeka teknikleri ile karşılaştırıldığında daha iyi sonuçlar verdiği gözlemlenmiştir.

### 3.2.1. Destek Vektör Makineleri - Sınıflandırma


Destek vektör makineleri sınıflandırma yaparken, genellemeleri optimize ederek sınıfları iyi ayırmayı öğrenmeyi ve bunu büyük veriler ile yapmayı amaçlamaktadır. Sınıflandırmadaki temel amaç ise örnek verilerden elde edilen bir fonksiyon ile daha önce görülmemiş veriler üzerinde bu fonksiyonu kullanarak doğru bir genelleme, dolayısı ile doğru bir sınıflandırma yapabilmektir. Bu sınıflandırma problemlerinde girdi, yani eğitim verileri her bir örnek veri için bir hedef değer ve örneğin bazı özelliklerini içerir. Destek vektör makineleri ise bu özelliklere göre hedef değeri tahmin etmeye çalışır. Bunu yaparken oluşan bir hiperdüzlemde uzaklıkları ve sınıflandırma hatalarını minimize etmeye çalışır. Bir hiperdüzlem üç boyutlu bir vektör uzayının herhangi bir bölümünü temsil edebilen iki boyutlu bir düzlemdir. Bir alt küme olarak ifade edilebilir [65].

#### 3.2.1.1. Maksimum Marj Destek Vektör Makineleri

Destek vektör makinelerinin ilk versiyonu maksimum marj sınıflandırıcı olarak ortaya çıkmıştır. Belirli bir kernel fonksiyonu için doğrusal olarak ayrılabilen veriler üzerinde çalışabildiği için gerçek dünyada ortaya çıkan birçok probleme uyarlanamamaktadır. Bu destek vektör makinesi en uygun ayırıcı hiperdüzlemi kullanan doğrusal bir diskriminant olarak ifade edilebilir. Aynı zamanda maksimum marjlı hiperdüzlem olarak ifade edilmektedir [65].

$N$  elemanlı  $\theta = \{x_i, y_i\}, i = 1, 2, \dots, N$  verinin kullanılması durumunda  $y_i \in \{-1, 1\}$  etiket/hedef değeri ve  $x_i \in R^d$  ise özellik vektörü olarak ifade edilir. Özellik vektörü ayrılabilir olarak kabul edilmekte ve bu ayrımın doğrusal bir sınır ile yapıldığı varsayılmaktadır. Burada girdi çok boyutlu olabilir fakat karar sınırı hiperdüzlem olarak ifade edilmektedir [65,66].

Şekil 3.16'da iki boyutlu  $x_i \in R^2$  doğrusal olarak ayrılabilir ve ayırım için kullanılması mümkün olan çok sayıda hiperdüzlem bulunan bir girdi için oluşturulan örnek oluşturulmuştur [65].



Şekil 3.16. Mümkün olan tüm ayırıcı doğrulardan iki tanesi, a) geniş marja sahip ayırıcı, b) dar marja sahip ayırıcı.

Şekil 3.16a'da geniş marja sahip bir ayırıcı elde edilmişken, Şekil 3.16b'de ise daha dar marja sahip bir ayırıcı elde edilmiştir. Her iki ayırıcı da sınıfları doğru şekilde ayırmayı başarmıştır. Maksimum marj destek vektör makinelerinde amaç eğitim hatasını yani ampirik riski minimuma indirecek, eğitim girdilerini doğru şekilde ayırabilen tüm hiperdüzlemler içerisinde maksimum marja sahip olanı bulmaktır. Şekil 3.16 incelendiğinde b figüründe marj küçük ve hiperdüzlem daha dar bir alanda olduğu için verilerin yanlış sınıflandırılma riski a figüründe olduğundan daha fazladır. Burada öğrenme gerçekleşirken karar fonksiyonuna ait (eşitlik 3.23)  $d(x,w,b)$  parametreleri hesaplanır [65,66].

$$d(x,w,b) = w^T x + b = \sum_{i=1}^n w_i x_i + b \quad (3.23)$$

$x$  hiperdüzlem üzerindeki bir noktayı temsil ederken,  $w$  ağırlık vektörünü  $b$  ise biası ifade etmektedir. Eğitim sonrasında öğrenme işlemi gerçekleştirilen vektör makinesi, eğitim setinde bulunmayan bir  $x$  değerini girdi olarak aldığı anda, eğitim sonucu elde ettiği fonksiyon sonucu  $o$  çıktısını oluşturur (eşitlik 3.24) [65].

$$i_F = o = \text{sig}(d(x, w, b)) \quad (3.24)$$

Burada  $o > 0$  ise yani  $d(x_p, w, b) > 0$  ise,  $x_p$  girdisi 1. Sınıf'a aittir. Bu durumda  $o = y_1 = +1$  olarak ifade edilir. Eğer  $o < 0$  ise, yani  $d(x_p, w, b) < 0$  ise,  $x_p$  girdisi 2. Sınıf'a aittir. Bu durumda  $o = y_2 = -1$  olarak ifade edilir.  $o = 0$ , yani  $d(x_p, w, b) = 0$  olan durumlar ise  $o$ 'nun 0'dan büyük ya da küçük olduğu durumlara göre daha düşük dereceli bir ayırıcı hiperdüzlemi ifade etmektedir [65].

Vektöre verilen girdiyi doğru şekilde ayırabilen birçok doğru sonuç bulunmakla birlikte istenirse karar fonksiyonu  $k$  sabit sayısı kadar arttırılabilir. Bu durumda eğer  $k$  pozitif bir sayı ise  $d(x, w, b)$  karar fonksiyonu  $d(x, kw, kb)$  şeklinde ifade edilir.  $k \neq 0$  ise karar fonksiyonu eşitlik 3.25'deki gibi ifade edilebilir [65].

$$\{x | w^T x + b = 0\} \equiv \{x | kw^T x + kb = 0\} \quad (3.25)$$

Eşitlik 3.25'te  $(w, b)$  ile  $(kw, kb)$  karar fonksiyonu parametreleri aynı hiperdüzlemi açıklayabildiği için eşitlik 3.26 ile minimum marj normalize edilebilir [65].

$$\min_{x_i \in X} |w^T x_i + b| = 1 \quad (3.26)$$

Burada  $x$  girdisinin pozitif ve negatif sınıflarında fonksiyonel marjı sağlayan  $w$  ağırlık vektörü sayesinde geometrik marj eşitlik 3.27 ve 3.28 ile açıklanabilir [65].

$$\langle w, x^+ \rangle + b = +1 \quad (3.27)$$

$$\langle w, x^- \rangle + b = -1 \quad (3.28)$$

Geometrik marjın hesaplanması sırasında  $w$  ağırlık vektörünün normalize edilmesi ihtiyacı oluşmaktadır. Bu nedenle geometrik marjı ifade eden  $y$ , elde edilen sınıflandırıcının fonksiyonel marjı olarak oluşmaktadır (eşitlik 3.29) [65].

$$y = \frac{1}{2} \left( \left\langle \frac{w}{\|w\|_2}, x^+ \right\rangle - \left\langle \frac{w}{\|w\|_2}, x^- \right\rangle \right)$$

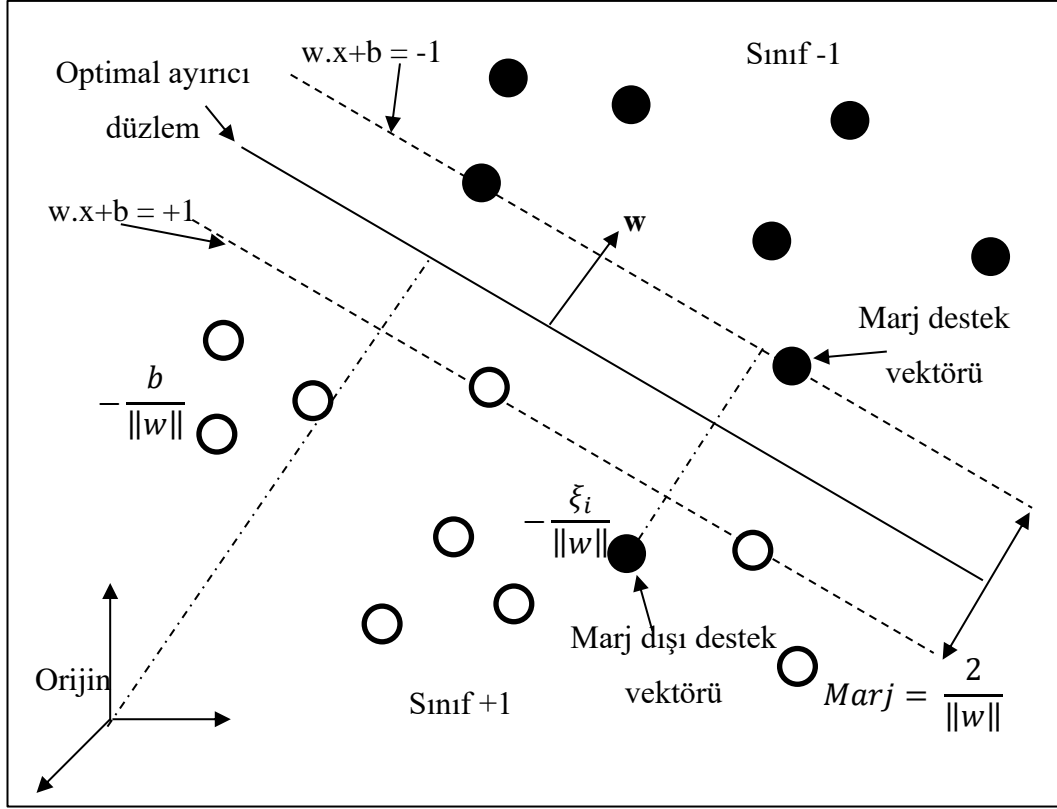
$$y = \frac{1}{2\|w\|_2} (\langle w, x^+ \rangle - \langle w, x^- \rangle) \quad (3.29)$$

$$y = \frac{1}{\|w\|_2}$$

### 3.2.1.2. Yumuşak Marj Destek Vektör Makineleri

Maksimum marj sınırlandırıcılara sahip destek vektörleri gerçek problemleri açıklamakta yeteri kadar iyi değildirler. Bunun sebebi de maksimum marj sınıflandırmada öğrenme algoritması doğrusal olarak ayrılabilen veriler için çalışmaktadır. Yani verilerin net bir şekilde birbirinden ayrımı mümkün olması, üst üste gelmiyor olması gerekmektedir. Doğrusal ayrılabilir olmayan veri kümelerinde doğrusal diskriminant fonksiyonu kullanılabilir ama bu durumda ya hatalar gürültü olarak kabul edilir ve gerçek dayanak hala doğrusaldır ya da sınıflandırılan veriler üst üste binebilir ve optimum karar fonksiyonu doğrusal kalır. Şekil 3.17’de doğrusal ayrılabilir olmayan veri setinde optimum ayırıcı düzlem gösterilmiştir.

Veri setinde tam olarak sınıflandırılmayan üst üste gelmiş veriler için ya da gürültüye sahip olan veriler için, marj içerisinde doğrunun doğru ya da yanlış tarafında olduğuna bakılmaksızın hatayı minimize etmek için yumuşak marjlar kullanılır. Maksimum marjda olduğu gibi eğitim hatasının sıfır olduğu bir hipotez gürültüye sahip olan verilerde kullanılamamaktadır.



Şekil 3.17. Doğrusal ayrılamayan veri seti için optimum ayırıcı hiperdüzlem.

Yumuşak marj destek vektör makineleri veriyi sıfır hata ile ayırmak yerine aynı özellikleri taşıyan verileri oluşan ayırıcı hiperdüzlemin aynı tarafında bırakacak bir fonksiyon türetmeyi amaçlamaktadır. Diğer bir deyişle marjı maksimize ederken sınıflandırma yanlışlıklarını minimize eden bir ayırıcı hiperdüzlem bulmak hedeflenir. Marj ile sınıflandırma yanlışlıkları arasındaki ilişki ise denkleme eklenen sabit pozitif sayı tarafından ayarlanır. Doğrusal olarak sınıflandırılmayan bu veriler için geometrik marjı maksimuma getiren ve hatayı minimuma indiren ayırıcı hiperdüzlem fonksiyonu eşitlik 3.30'da verilmiştir [66].

$$\Phi(\xi) = \sum_{i=1}^l \xi_i^\sigma \quad (3.30)$$

Burada  $\sigma$  genellikle 1 olarak alınır, amacı ise basit bir optimizasyon sunmaktır. Denkleme eklenen bu kukla değişkenler ile birlikte oluşan fonksiyon eşitlik 3.31'de verilmiştir [67].

$$y_i[w^t x_i + b] \geq 1 - \xi_i, \quad \xi_i \geq 0 \quad (3.31)$$

Kukla deęişkenleri sınıflandırma düzlemlerini esnetmek için kullanılmaktadır. Burada  $\xi_i > 1$  ise  $x_i$  yanlış olarak ayrılmış denilebilir.  $\xi_i/\|w\|$  açık geometrik alandır ve  $x_i$ 'nin ait olduęu sınıfın hiperdüzlemden olan uzaklığını ifade eder.  $\xi_i$  pozitif olması demek  $x_i$ 'nin kendi sınıfından aksi yönde bir konumda bulunduęu anlamına gelmektedir. Bu uzaklığı minimize edebilmek için maksimum yerine optimum bir ayırıcı hiperdüzlem arayışı türemiştir. Optimum ayırıcı hiperdüzlem eřitlik 3.32'de verilen fonksiyonun minimize edilmesi ile elde edilir.  $F(u)$  sürekli artan bir fonksiyon iken  $C$  ise sabittir ve maliyeti temsil eder.

$$\frac{1}{2}w^2 + CF(\sum_{i=1}^l \sigma_i^\sigma) \quad (3.32)$$


### 3.2.1.3. Doğrusal Olmayan Destek Vektör Makineleri

İdealde verilerin doğrusal ayrılması beklenirken gerçekte bu durum pek olası olmayabilir. Destek vektör makineleri doğrusal olmayan verilere kolay bir şekilde uyum sağlayabilir. Bunu sağlamak için eğitim verilerinin özelliklerini algılayabilmek adına doğrusal olmayan bir özellik uzayı  $\Phi(\vec{x}_i)$  oluşturulur. Doğrusal olmayan destek vektör makineleri bu özellik uzayında gözlem vektörünü yüksek dereceye sahip bir uzayda başka bir vektöre dönüřtürerek yeni bir doğrusal sınıflandırıcı elde etmeyi amaçlar [64]. Sınıflandırma fonksiyonu bu yeni oluşturulan yüksek dereceli uzayda doğrusal iken, orijinal veri uzayında doğrusal deęildir.

Yüksek dereceli uzayın oluşturulması için boyutların arttırılması gerekmektedir. Böylece yeterince sayıya sahip boyutlar veri doğrusalmış gibi davranabilir (Şekil 3.18). Genellikle  $\Phi(x)$  fonksiyonu mevcut deęildir, hesaplanamaz. Bu nedenle özellik uzayında ve örüntü uzayında iki vektör için iç çarpım hesapları yapılması gerekmektedir. Yani  $\Phi(x)$  elde edilemezken,  $\Phi(x_1)^T \Phi(x_2)$  elde edilebilir. Bu hesaplama için ise kernel çekirdekleri kullanılır (eřitlik 3.33).

$$K: R^d \times R^d \rightarrow R: K(x_1, x_2) = \Phi(x_1)^T \Phi(x_2) \quad (3.33)$$





Şekil 3.18. Doğrusal ayrılmayan verilerin doğrusal ayrılabilir hale getirilmesi a) doğrusal ayrılmayan veri, b) doğrusal ayrılmış versiyonu.

İç çarpım yapıldığından dolayı langranj çarpanlar kümesi  $\Lambda = (a_1, a_2, \dots, a_i)^T$  fonksiyona dahil edilir. Nihai olarak elde edilen optimum ayırıcı hiperdüzlem eşitlik 3.34’de verildiği gibidir. DV destek faktörlerini ifade eder. Doğrusal olmayan destek faktörleri için sınıflandırıcı ise eşitlik 3.35’deki gibi hesaplanır.

$$\sum_{DV} a_i y_i K(x_i, x) + b = 0 \quad (3.34)$$

$$f(x) = y = \text{sig}(\sum_{DV} a_i y_i K(x_i, x) + b) \quad (3.35)$$

Doğrusal olmayan destek vektör makinelerinde kerneller karar verme aşamalarında son derece önemlidirler.

### 3.2.2. Destek Vektör Makineleri – Regresyon

Destek vektör makineleri regresyon modellerinde de sınıflandırma modellerinde olduğu gibi doğrusal ve doğrusal olmayan veriler kullanılabilir. Sınıflandırma modellerinde olduğu gibi regresyonda da doğrusal olmayan modellerde kernel çekirdek fonksiyonları kullanılır [64]. Destek vektör makinelerinde regresyon makinelerin öğrenme karmaşıklıkları yüksek ise bu makinenin çok iyi öğrenebildiği anlamına gelmektedir. Fakat bu makinenin iyi bir tahmin yaptığı anlamına gelmez. Makine eğitim verisine aşırı adapte olmaktadır. Az öğrenme karmaşıklığına sahip bir makine ise iyi bir şekilde öğrenme işlemini gerçekleştiremeyebilir. Regresyon destek

vektör makinelerinde ayırıcı hiperdüzlem ile vektörler arasındaki marja bakılmaz, bunu yerine gerçek değer ile tahmin değeri arasındaki hataya bakılır (eşitlik 3.36).

$$R_{reg} = C \sum_{i=1}^l |y_i - f(x_i)|_\varepsilon + \frac{\|w\|^2}{2} \quad (3.36)$$

Eşitlik 3.36'da  $\sum_{i=1}^l |y_i - f(x_i)|_\varepsilon$   $x_i$  gözlem verileri ile  $y_i$  tahmin verileri arasındaki hataların toplamını ifade eder ve kayıp ya da hata fonksiyonu olarak ifade edilir.  $\|w\|^2$  destek vektör makinelerinin öğrenme ağırlığını belirtirken,  $l$  eğitim verisinin büyüklüğü ve  $C$  ise hatayı sınırlamak için kullanılan sabit terimi, ceza katsayısını ifade eder.

### 3.2.2.1. Destek Vektör Makineleri – Doğrusal Regresyon

Klasik bir regresyon verisinde  $\{(x_1, y_1), \dots, (x_l, y_l)\}$ , her  $x_i$  girdi değeri girdi uzayında bir noktaya karşılık gelirken aynı zamanda  $y_i$  çıktı değerine sahip olur. Vapnik tarafından önerilen  $\varepsilon$ -duyarsız bir destek vektör makinesi ile regresyon modellerinde marj kavramını kullanmayı mümkün kılmaktadır. Böylece eğitim verileri için her bir  $y$ 'den en fazla  $\varepsilon$  kadar hataya izin veren bir fonksiyon oluşturması mümkün olmaktadır. Modelin esnekliğinin sağlanması ve gerçek hayattaki problemlere uyarlanabilmesi için langranj teorisi modele dahil edilmiştir [68]. Böylece destek vektör makinelerinde doğrusal regresyon problemleri için eşitlik 3.37 elde edilir.

$$f(x) = \sum_{i=1}^l (a_i - a_i^*) \langle x_i, x \rangle + b \quad (3.37)$$

Burada  $a_i$  ve  $a_i^*$  langranj çarpanları ayar kuvvetleri olarak iş görür ve  $y_i$  değerini gerçek  $y$  değerine itmeye çalışarak doğru tahmin yapmayı amaçlar. Regresyon modelini doğru tahmin etmek için bu langranj çarpanlarının sıfırdan farklı değerlere sahip olması gerekmektedir [66].

### 3.2.2.2. Destek Vektör Makineleri – Doğrusal Olmayan Regresyon

Önceki bölümlerde bahsedildiği üzere destek vektör makineleri ilk etapta doğrusal problemler için geliştirilmiş fakat gerçekte yaşanan problemler doğrusal olmadığı için, bu problemleri çözmek üzere yeni versiyonları geliştirilmiştir. Doğrusal olmayan problemlerin çözümü için destek vektör makineleri girdi uzayından daha yüksek boyutta bir özellik uzayı oluşturur ve verileri doğrusal olarak yerleştirir. Böylece destek vektör makinelerinin genelleme kabiliyeti yükseltilmiş olur. Fakat bu özellik boyutlarının sayısının yüksek olması işlem zorluğunu dolayısı ile de makinelerin öğrenmesini ve tahmin performansını düşürmektedir. Bu sorunu çözmek için destek vektör makineleri kernel çekirdeklerini kullanmaktadırlar. Temelde makine yüksek özellik uzayında doğrusal bir çözüm oluşturur. Oluşturulan bu çözüm için yapısal risk minimizasyonu kullanılır. Elde edilen bu doğrusal çözüm kernel çekirdekleri yardımıyla doğrusal olmayan girdi uzayına aktarılır. Doğrusal olmayan regresyon modeli için kernel kullanılan matematiksel fonksiyon Eşitlik 3.38'de verildiği gibidir [68].

$$W(a, a^*) = -\frac{1}{2} \sum_{i,j=1}^l (a_i - a_i^*)(a_j - a_j^*) K(x_i - x_j) - \varepsilon \sum_{i=1}^l (a_i - a_i^*) + \sum_{i=1}^l y_i (a_i - a_i^*) \quad (3.38)$$

Burada;

$$\sum_{i=1}^l (a_i - a_i^*) = 0,$$

$$a_i, a_i^* \in [0, C] \text{ ve } i = 1, \dots, l$$

Destek vektör makinelerinde modellenen regresyon problemleri için en önemli üç faktör hata faktörü  $\varepsilon$ , ceza faktörü  $C$  ve kernel fonksiyonudur.

Hata faktörü kabul edilebilir hata alt ve üst sınırlarını belirler ve eğer tahmin edilen değer hata sınırı içerisindeyse kayıp sıfır olarak kabul edilir. Eğer hata sınırı çok geniş ise tahmin doğruluğu düşecek fakat destek vektör makineleri modele daha az destek vektörü atayacağı için model hızlı çalışacaktır. Eğer hata limiti çok dar tutulur

ise tahmin doğruluğu artacaktır fakat modelin çalışması atanacak destek vektörünün sayısıyla doğru orantılı olarak artacaktır.

Ceza faktörü ise hata limitinin üzerinde gerçekleşen hatalara uygulanarak regresyon modelinin daha düşük bir tahmin yapmasını sağlamaktadır. Eğer ceza faktörü düşük tanımlanır ise regresyon modeli daha rahat davranacağı için tahmin hataları fazla olabilir.

Kernel faktörü daha çok verinin yapısıyla alakalıdır ve tahmin doğruluğunu doğrudan etkilemektedir [65].

### **3.3. RASTGELE ORMANLAR**

Karar ağaçları makine öğrenmesi tekniklerinin en bilinen ve en çok kullanılan yöntemlerinden biridir. Genellikle sınıflandırma problemleri için kullanılmaktadır regresyon problemlerine de uyarlanabilmektedir. Fakat karar ağaçlarının en büyük dezavantajlarından biri kuruluş aşamasında ağacın doğru olarak kurulamamasıdır. Rastgele ormanlar birçok karar ağacının bir araya gelmesi sonucu oluştuğu için karar ağaçlarının bu dezavantajını ortadan kaldırmaktadır. Birçok karar ağacının bir araya gelmesi sonucu oluştuğu için rastgele ormanlar adını almıştır [69].

RO yöntemi Brieman tarafından 2001 yılında önerilmiştir. Karar ağaçlarında ağaç boyunun optimizasyonu ve ağacın eğitim verisine aşırı uyumunu engellemek için önerilen, eğitim verisinden rastgele örnek bir alt eğitim kümesi seçilmesi fikrinin üzerine inşa edilmiştir. RO algoritması verilerin eğitimi sırasında çok sayıda karar ağacı oluşturmak ve oluşan bu küçük ağaçlardan gelen bilgileri modelin türüne göre, birleştirmeye çalışmaktadır. Kurulan model eğer sınıflandırma ise sınıfların ortancaları, regresyon ise tahminlerin ortalaması alınarak birleştirme işlemi yapılır [70].

RO yöntemi non-parametrik istatistiksel testler arasında yer almaktadır ve tek ve çok yönlü sınıflandırma ile regresyon modellerinde tercih edilen güçlü bir yöntemdir. RO yöntemi bağımsız değişken sayısının yüksek olduğu modellerde ve eksik-kayıp

verilerin bulunduğu modellerde yüksek tahmin performansına sahiptir. Ayrıca bağımsız değişkenleri önem derecesine göre sıralayabilmektedir [71].

RO yönteminde bir diğer önemli parametre ise eğitim setinin ayarlanmasıdır. Eğer kurulan model için bir test verisi yok ise RO eldeki verinin dağılımını dikkate alarak 2/3'ünü öğrenmeye (inBag), 1/3'ünü ise teste (Out-Of-Bag-OOB) ayırarak modeli kurar. Kullanılacak karar ağacı kullanıcı tarafından belirlenir ve her bir ağaç için örneklem oluşturulur. Her bir örneklem için ise inBag ve OOB verileri oluşturularak kurulan ağaçlar bu OOB ile test edilir ve hata oranları elde edilir. Hata oranlarının ortalaması alınan karar ağaçlarının OOB hatası hesaplanmış olur [69,72].

RO yöntemi karar ağacının oluşturulması aşamasında CART (Classification and Regression Trees) karar ağacı yöntemini kullanmaktadır. CART karar ağacında GINI indeksi kullanılarak oluşturulan ağaçların performansı ölçülür ve ağaçlar dallandırılır. Fakat CART karar ağaçlarından farklı olarak RO yönteminde ağacın büyütülmesi için veri setinin tamamı kullanılmamaktadır. Ayrıca yeni bir ağacın oluşturulmasında kullanılacak olan değişkenler için kısmen ya da tamamen rastgele seçim yapılmaktadır. Rastgele yapılacak olan bu seçimde kullanılacak özelliklerin seçimi ise en başarılı bölünmeyi sağlayan özelliklere göre yapılmaktadır. Böylece mümkün olan en büyük büyüme sağlanır [69–72].

GINI katsayısı için eşitlik 3.39'daki denklem kullanılmaktadır [71]. P veri seti sınıfını, j göreceli frekansı ve  $p(j/t)$  ise t düğümündeki j sınıfına ait göreceli olasılığı ifade etmektedir.

$$Gini(t) = 1 - \sum_j [p\left(\frac{j}{t}\right)]^2 \quad (3.39)$$

### 3.3.1. Rastgele Ormanlar Algoritması

RO yöntemi için genel olarak kullanılan algoritma hem sınıflama hem de regresyon modelleri için aşağıda verilmiştir [69,71,72].

1. Veri setinden  $n$  adet hızlandırma (bootstrap) örnekleme yapılır ve bu örneklemenin  $2/3$ 'ü ağaç oluşturulurken öğrenme verisi olarak  $1/3$ 'ü ise test verisi kullanılır.
2. Eğitim verisi içerisinde  $m$  adet değişken rassal olarak seçilir ve bu değişkenler arasından en iyi bölünmeyi sağlayacak olanlar belirlenir. Regresyon modelleri için tahmin değişkeni  $m=p/3$ , sınıflandırma modelleri için ise  $m=p^{1/2}$  olarak hesaplanır.  $p$  tahmin için kullanılan toplam değişken sayısıdır.
3. GINI indeksini kullanarak ağacın dallanması için etkili olan girdi değişkenleri puanlanır ve puana göre ağaç dallara ayrılır. Bu işlem daha fazla alt dal oluşturulamayana kadar devam eder.
4.  $n$  adet karar ağacı oluşturulana kadar önceki adımlar tekrarlanır ve her bir ağaç için tahmin hataları hesaplanır. Regresyon modellerinde ağaçların elde ettiği puanların ortalaması dikkate alınırken, sınıflandırma modellerinde ise en doğru tahmini yapan ağacın tahmini tüm ormanın tahmini olarak kabul edilir.

Eğitim verileri kullanılarak tahmin hatalarının hesaplanması ise aşağıdaki gibidir.

1. Her yeni bootstrap işleminde eğitim ve test verisi olarak ayrılan veri setinden eğitim verilerini (InBag) kullanarak ağaç eğitilir.
2. Eğitilen ağaç test verileri (Out-Of-Bag, OOB) için tahmin oluşturularak OOB hata oranı hesaplanır.
3. Her bir ağaç için oluşturulan bu OOB hatası oranını kullanarak tüm ağaçlar için hata oranı hesaplanır.

RO yönteminde orman içerisinde oluşturulan karar ağaçları arasında bir korelasyon yoktur. Yüksek korelasyon olması durumunda modelin hata oranı yükselir. Ayrıca her bir bireysel ağaç iyi bir performansa sahip olmalıdır. Böylece ormanın hata oranı düşer [71].

### 3.3.2. Bağımsız Değişkenlerin Önem Derecesi

Tahmin modellerinde bağımsız değişkenlerin bağımlı değişken üzerindeki etkisi önemlidir. Birçok bağımsız değişkenin bulunduğu veri setlerinde hangi değişkenlerin, ne derece tahmini etkilediğinin belirlenmesi, gerekirse tahmin üzerinde etkisi olmayan değişkenlerin modelden çıkartılarak gürültüyü azaltması gerekebilir. Değişkenlerin öneminin belirlenmesi karmaşık bir problemdir ve literatürde bulunan birçok çalışmada değişkenler arasındaki korelasyon yardımı ile bu önem derecesini belirlenmeye çalışılmıştır. RO yönteminde değişkenlerin önem derecesi hesaplamak için iki yöntem kullanılır.

Diğer karar ağaçları tarafından da kullanılan GINI indeksi RO yönteminde de kullanılmaktadır. Temel olarak karar ağacı oluşturulurken değişkenin ağacın oluşturulmasında oynadığı rol puanlanır. Kullanıcının girdiği sayıda karar ağacı oluşturulduktan ve tüm puanlar hesaplandıktan sonra, puanlar toplanır ve normalleştirilerek sıralanır.

Bir diğer yöntem ise değişkenlerin işlem sırasında hassaslık analizi ile önemlerinin belirlenmesidir. Buna göre diğer tüm değişkenler sabit bırakılıp sadece bir değişkenin değeri değiştirilerek ağacın çıktısına bakılır ve OOB değeri hesaplanır. Tüm ağaçlar için bu işlem yapıldıktan sonra oluşan OOB'lerin ortalaması hesaplanarak değişkene puan atanır. Tüm değişkenler için bu hesaplama yapıldıktan sonra elde edilen ortalamaların farklarının standart sapması hesaplanır ve değişken ortalamaları bu standart sapmaya bölünerek değişkenin önem derecesi belirlenmiş olur.

### 3.3.3. Değişkenler Arası Yakınlık

RO yönteminde her ağacın birbirinden farklı değişkenlere sahip olması istenmektedir, böylece ağaçlar arası korelasyon düşük olacaktır. Bu değişkenlerin seçim işlemi kısmen rastgele olarak yapılmaktadır. Fakat RO bu bilgiyi tutar ve ağaçlar dallara ayrılırken en iyi performansı sağlayan değişkenlerin kullanılması amaçlanır.

Değişkenler arası yakınlığın hesaplanabilmesi için RO yöntemi, iki değişkenin ne sıklıkla aynı terminale düştüğüne dikkat eder. Bu bilgi ile birlikte bir yakınlık matrisi oluşturur ve yakınlık matrisinde bulunan değerler RO'daki ağaç sayısına bölünerek normalleştirilmiş yakınlık matrisi hesaplanır. 0 ile 1 arasında değişen bu değer 1'e yakınsa ormanın benzer olduğu, 0'a yakınsa ormanda bulunan ağaçların farklı olduğu yorumu yapılabilir [69,71].

#### **3.3.4. Kayıp Verilerin Tahmini**

Verilerin elde edilmesi süreçlerinde yaşanan problemlerden dolayı veri setleri tam anlamıyla oluşturulamayabilir, gözlem ya da eksik veri bulunabilir ya da veriler hatalı olabilir. Literatürde bulunan birçok teknik eksik veriler ile çalışmamaktadır.

RO yönteminin en önemli özelliklerinden biri de kayıp veriler ile işlem yapabilme becerisidir. Kayıp verilerin tahmini için RO yöntemi yakınlık matrisini kullanır. Kayıp verinin bulunduğu değişken eğer sürekli ise değişkenin sahip olduğu gözlemlerin medyan değeri alınır, eğer değişken kategorik bir değişken ise en çok görülen gözlem kayıp veri için atanır. RO hesaplanan kayıp veri ile iterasyonlara başlayarak yakınlık matrisini oluşturur. Matriste hesaplanan uzaklıklar ile ilgili ağırlıklandırma yapılır. Değişkenin sürekli olması durumunda gözlemlerin ağırlıklı ortalama uzaklığı kayıp veri olarak kaydedilir. Eğer değişken kategorik ise gözlemlerde en yüksek uzaklığa sahip değer kayıp veri olarak atanır. Bu işlem birkaç defa tekrarlandıktan sonra nihai değer hesaplanabilir [69,71].



## **BÖLÜM 4**

### **UYGULAMA**

Bu çalışmada perakende hazır giyim alanında faaliyet gösteren bir firmanın satışlarının tahmin edilmesi amacı ile yapay zeka tekniklerinden yapay sinir ağları, destek vektör makineleri ve rastgele ormanlar yöntemleri kullanılmıştır. Uygulanan yöntemin geleneksel yöntemler ile karşılaştırılmasının yapılması ve başarı oranının belirlenmesi amacıyla ağırlıklı ortama yöntemi de uygulanmış olup elde edilen sonuçlar Bölüm 6 Sonuçlar ve Tartışma bölümünde irdelenmiştir.

#### **4.1. UYGULAMANIN YAPILDIĞI FİRMA**

Uygulama yapılan firma hazır giyim alanında faaliyet gösteren bir perakende firmasıdır. 2000’li yıllardan beri ilgili sektörde faaliyet gösteren firma günümüzde yurt içi ve yurt dışı olmak üzere 47 ülkede toplam 1000’in üzerinde mağazaya sahiptir. Yaklaşık 5000 çalışanı merkez ofiste bulunan firma toplamda 45 000’den fazla kişiyi istihdam etmektedir.

Firma temel olarak hazır giyim ürünleri üzerine faaliyet göstermekte fakat hazır giyimin yanı sıra giyim aksesuarı, oyuncak, kozmetik ve ev tekstili gibi ürün gruplarına da mağazalarında yer vermektedir. Hazır giyim ürün grupları demografik olarak kadın giyim, erkek giyim, kız çocuk, erkek çocuk, kız bebek, erkek bebek ve yeni doğan olmak üzere yedi ana gruba ayrılmaktadır. Bu ana grupların her biri ise ürün özelliklerine ve müşteri profillerine göre alt gruplara ayrılmaktadır. Örnek olarak erkek giyim grubu klasik erkek giyim, günlük erkek giyim, basic (sade/standart ürünler) erkek giyim gibi alt gruplara ayrılmaktadır. Ayrıca her alt grup ürün yapısı itibari ile örme, triko, dokuma, denim, dış giyim ve yüzme giyim olarak sınıflandırılmakta ve ürün tarzı anlamında sade ve modayı takip eden ürünler olmak üzere sınıflandırılmaktadır. Tüm bu kırımlar ürünlerin yaşam ömürlerini

etkilemekte ve bu durum sade/basit ürünlerde 12 haftaya kadar uzarken, moda ürünlerinde ise 4-6 hafta arasında kalmaktadır.

#### 4.2. ÇALIŞMANIN KAPSAMI VE VERİ SETİ

Bu çalışma kapsamında perakende hazır giyim alanında faaliyet gösteren firmanın 2014 49. haftası ile 2018 52. haftası arasında kadın giyim ve erkek giyim ana grubunda yer alan “kadın never-out-of-stock (NOS)” ile “erkek never-out-of-stock (NOS)” ekiplerinin yaptıkları satışlar kullanılmıştır. Bu ekiplere ait örme, triko, dokuma ve denim ürün grupları çalışma kapsamına alınmıştır. Ayrıca çalışma kapsamında sadece yurt içi satışları dikkate alınmıştır.

Çizelge 4.1’de çalışmada kullanılacak veri setinin 2017 yılı 1. haftaya ait bir bölümü verilmiştir. Satış verileri hafta bazında düzenlenmiş ve bu çalışmada satış tahmini hafta bazında yapılmıştır. Çizelge 4.1’de yer alan tablo başlıklarından “Satış Adeti (AF)” kurulacak modellerde çıktı verisi olarak kullanılmış diğer alanlar ise girdi verisi olarak kullanılmıştır. Veri setinde hem kategorik hem de aralığa ait veriler bulunmaktadır. Çalışmada kullanılan girdi değişkenleri aşağıdaki açıklanmıştır.

**Ürün Adı (A):** Tahmini yapılan ürünlerin adı

**Renk (B):** Tahmini yapılan ürünlerin rengi

**Hafta:** Satışın gerçekleştiği hafta

**Cinsiyet (C):** Ürünün ait olduğu cinsiyet grubu (0=erkek, 1=kadın)

**Özel Gün (D):** İlgili gerçekleştiği haftada özel gün var mı? (1=evet, 0=hayır)

**Hava Durumu (E):** İlgili hafta için ağırlıklandırılmış hava durumu

**Mağaza Sayısı (F):** Ürünün satıldığı mağaza sayısı

**Asgari Ücret (G):** İlgili dönemdeki asgari ücret (TL-Aylık)

**Giyim Sanayi Üretim Endeksi (H):** Giyim eşyaları imalatı üretim endeksi (Aylık)

**Turist Sayısı (I):** Ülkeye gelen ziyaretçi sayısı (Aylık)

**Turist Başına Harcama (J):** Kişi başına ortalama harcama (USD-Aylık)

**Altın Gram (K):** Külçe altın gram satış fiyatı (TL-Aylık)

**Tüfe Giyim (L):** Tüketici giyim fiyat endeksi (Aylık)

**Üfe Tekstil (M):** Yurtiçi üretici giyim fiyat endeksi (Aylık)

**Güven Endeksi (N):** Reel kesim güven endeksi (Aylık)

**Giyim Kapasite (O):** Giyim eşyalarının imalat düzeyi (Aylık)

**İşsizlik (P):** İşsizlik oranı (Aylık)

**İstihdam (R):** İstihdam oranı (Aylık)

**Vip (S):** Ürünün ilgili hafta için vip statüsünde olup olmadığı (1=vip, 0=vip değil)

**Giyim KK Harcama (T):** Giyim ve aksesuar için banka kartı ve kredi kartı harcama tutarı (Haftalık-Bin TL)

**USD (U):** ABD Doları döviz alış kuru (Haftalık-TL)

**Faiz (V):** Bankalara açılan ihtiyaç kredilerine uygulanan ağırlıklı ortalama faiz oranları (Haftalık)

**Verilen Kredi (Y):** Verilen kredi tutarı (Haftalık-Bin TL)

**Gün Sonu Reyon Stok (Z):** İlgili mağazalarda gün sonunda bulunan stok miktarı

**Brüt Kar (AA):** İlgili mağazalarda satılan ürünlerden elde edilen brüt kar (TL)

**Tutar (AB):** Satılan ürün tutarı (TL)

**Fiyat (AC):** İlgili ürünün gerçekleşen satış fiyatı

**PSF (AD):** İlgili ürünün etiket satış fiyatı

**Store Cover (AE):** İlgili mağazalarda gün içinde reyonda bulunan stok miktarı/satış adeti

**Satış Adeti (AF):** İlgili ürünün toplam satış adeti

Çizelge 4.1. Çalışmada kullanılan verilerin 2011 yılı 1. haftaya ait bölümü.

Hafıza	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O
201701	HRK,CANSU	GRI	1	1	1,6	84	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,CANSU	SIYAH	1	1	1,6	78	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,GATI	BEJ	1	1	1,6	37	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,GATI	GRI	1	1	1,6	205	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,GATI	HAKI	1	1	1,6	222	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,GATI	INDIGO	1	1	1,6	203	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,GATI	KIRMIZI	1	1	1,6	31	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,GATI	MAVI	1	1	1,6	74	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,GATI	PEMBE	1	1	1,6	222	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,GATI	SARI	1	1	1,6	42	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,GATI	SIYAH	1	1	1,6	116	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,GATI	YESIL	1	1	1,6	215	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,GETTO	BEJ	1	1	1,6	1	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985
201701	HRK,GETTO	PEMBE	1	1	1,6	2	1 777,5	96,69	1 184 957	424	144,58	177,38	283,23	97,1	77,24985

Çizelge 4.1. (devam ediyor).

P	R	S	T	U	V	Y	Z	AA	AB	AC	AD	AE	AF
13	44.8	0	845005	3,5593	16,22	164 025 233	3	1 243,222	4 295,531	64,37583	29,95	0,666933	234
13	44.8	0	845005	3,5593	16,22	164 025 233	1	2 356,891	8 124,381	46,13296	29,95	0,205386	441
13	44.8	1	845005	3,5593	16,22	164 025 233	0	551,3519	1 335,61	45,81083	29,95	0,110438	53
13	44.8	0	845005	3,5593	16,22	164 025 233	1	9 138,5	20 203,35	46,07213	29,95	0,285335	733
13	44.8	0	845005	3,5593	16,22	164 025 233	1	14 258,39	31 758,55	45,91054	29,95	0,080731	1155
13	44.8	0	845005	3,5593	16,22	164 025 233	2	19 162,14	42 830,24	45,6175	29,95	0,358323	1552
13	44.8	1	845005	3,5593	16,22	164 025 233	2	745,1336	1 633,519	27,68676	29,95	0,078122	59
13	44.8	2	845005	3,5593	16,22	164 025 233	15	1 889,136	10 811,06	54,38845	29,95	0,383982	594
13	44.8	1	845005	3,5593	16,22	164 025 233	2	7 702,474	20 009,99	64,01034	29,95	0,123769	814

Çalışmada ayrıca ürünlerin tek tek tahmin performansları mı yoksa tüm ürünlerin tek bir seferde tahmin edilmesi mi daha iyi sonuç verir sorusuna da cevap aranmaktadır. Bu nedenle kurulan tüm tahmin modelleri için tüm ürünlerin dahil olduğu veri seti ve bu verinin her bir ürün için ayrılmış versiyonu tüm modellere uygulanacaktır. Veri setinde toplam 13 ürün ve 14 245 adet gözlem bulunmaktadır.

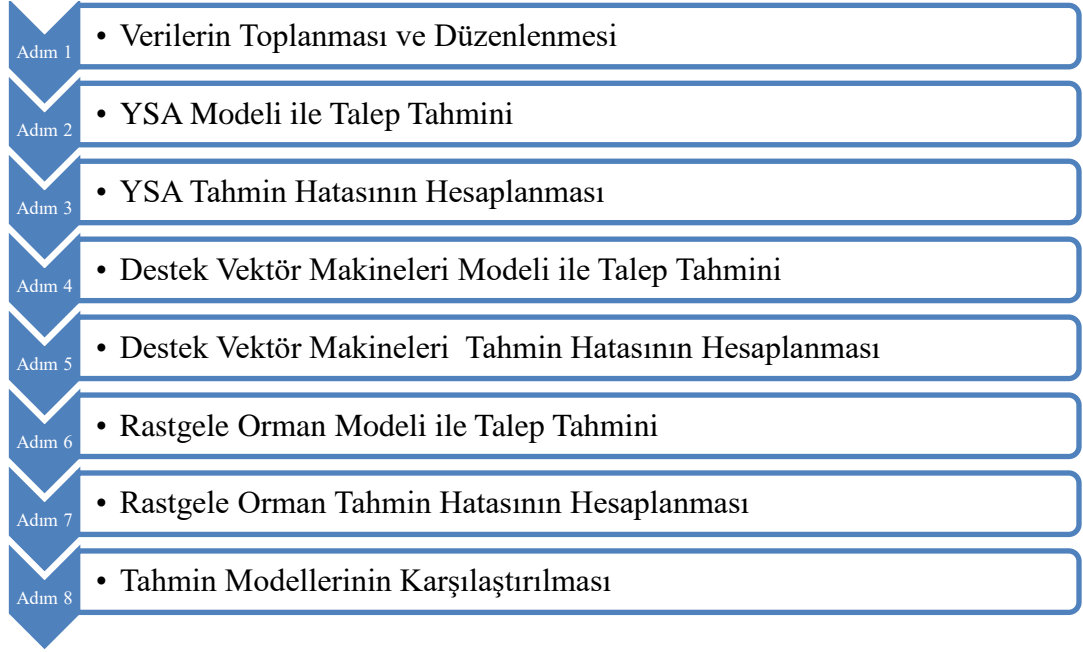
### **4.3. UYGULAMA ARAÇLARI**

Çalışmada kullanılacak yöntemler için uygun yazılımlar araştırılmış ve kullanım esnekliği de göz önünde bulundurularak yapay sinir ağları, destek vektör makineleri ve rastgele ormanlar yöntemleri için gerekli modelin kurulmasında R programlama dili tercih edilmiş ve genel kamu lisansına sahip olan R Studio programı 1.2.5033 versiyonu kullanılmıştır. R programlama dilinin tercih edilmesindeki en önemli nedenlerden biri de veri manipülasyonu konusunda oldukça başarılı olması ve yapay sinir ağları, destek vektör makineleri ve rastgele ormanlar dahil birçok kütüphaneyi bünyesinde bulundurmasıdır [73].

R programlama dili Robert Gentleman ve Ross Ihaka tarafından 1976 yılında Auckland Üniversitesinde geliştirilmiş ve açık kaynak olarak tüm kullanıcıların kullanımına sunulmuştur. Yazılım veri madenciliği, istatistik, yöneylem araştırması gibi kütüphanelere sahiptir ve aktif olarak gönüllüler tarafından geliştirilmektedir [74,75].

### **4.3. TAHMİN ANALİZLERİ**

Çalışmanın yapıldığı firmadan toplanan veriler ham hali ile çalışmada kullanılacak yöntemlere uyumlu olmadığı için, veriler üzerinde bir takım düzeltme işlemleri yapılmıştır. Daha sonra sırasıyla yapay sinir ağları, destek vektör makineleri ve rastgele orman modelleri için tahmin analizi hem renk detaylı veride hem de renk detayı olmayan veride gerçekleştirilmiştir. Çalışma sırasında izlenecek adımlar Şekil 4.1'de yer alan akış şemasında verildiği gibidir.



Şekil 4.1. Uygulama akış şeması.

Şekil 4.1’de verilen uygulama adımları hem renk detaylı veri için hem de renk detaysız veri için aynı şekilde ilerlemektedir.

### 4.3.1. Tahmin Performans Kriterleri

Tahmin hatalarının hesaplanmasında farklı yöntemlerin kullanılması nedeniyle ortak bir performans kriteri ihtiyacı hissedilmiş ve bu nedenle literatürde yaygın olarak kullanılan performans kriterleri göz önünde bulundurulmuştur. Kullanılan bu kriterler, ortalama mutlak hata (Mean Absolute Error-MAE), ortalama hata karesi (Mean Square Error-MSE), hata kareleri ortalamasının karekökü (Root Mean Square Error-RMSE) ve  $R^2$  şeklinde sıralanabilir. Tüm denklemlerde  $y_i$  gözlem değerini,  $\hat{y}_i$  tahmin değerini ve  $n$  gözlem sayısını ifade etmektedir.

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (4.1)$$

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (4.2)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (4.3)$$

$$R^2 = \frac{\sum (y_i - \hat{y}_i)^2}{\sum (y_i - \bar{y}_i)^2} \quad (4.4)$$

Modellerin performansları ölçülürken eğitim ve test verisinin ayrılmasında literatürde sıkça kullanılan iki yöntem bulunmaktadır. Bunlardan biri bekletme (hold out), diğeri ise çapraz doğrulama (cross validation) yöntemidir. Bekletme yönteminde temel olarak verinin bir kısmı (%70 ya da 2/3) eğitim verisi olarak modele verilirken, geriye kalan kısım (%30 ya da 1/3) test verisi olarak kenarda tutulmaktadır. Model eğitimi tamamladığında ise kenarda tutulan test verisi ile test edilerek performansı ölçülebilir [72].

Çapraz doğrulama yönteminde ise veriler eşit olarak n sayıda alt kümeye ayrılır ve bu alt kümelerden biri test verisi olarak seçilirken diğeri n-1 veri kümesi ise eğitim verisi olarak modele verilir. Bu işlem n defa tekrarlanarak her seferinde yeni bir test kümesi ve n-1 eğitim kümesi oluşturulur, böylece veri setinde tüm veriler hem test hem de eğitim verisi olarak modele verilmiş olur. n adet işlemden sonra modelin performansı n adet işlemin hatalarının ortalaması olarak elde edilir. Çapraz doğrulama için alt küme sayısı literatürde yaygın şekilde 10 olarak kullanılır [72].

#### **4.3.2. Yapay Sinir Ağı Tahmin Uygulaması**

Bu bölümde R Studio programında kullanılmış ve veri seti üzerinden tahmin çalışması yapılmıştır.

Literatürde yapay sinir ağının kaç katmandan ve hücreden oluşması gerektiği ile ilgili bir yöntem yoktur. Yapılan çalışmalarda deneme-yanılma yolu ile en iyi performansı veren ağ modelinin seçildiği görülmüştür. Bu nedenle en iyi modelin seçimi için farklı ağ yapıları kullanılmış ve en uygun olan seçilmiştir. En uygun sinir ağının seçiminde tüm verilerin %70'i modele verilmiş, modelin doğrulanması için çapraz doğrulama yöntemi kullanılmış ve alt küme sayısı 10 olarak alınmıştır. Geriye kalan

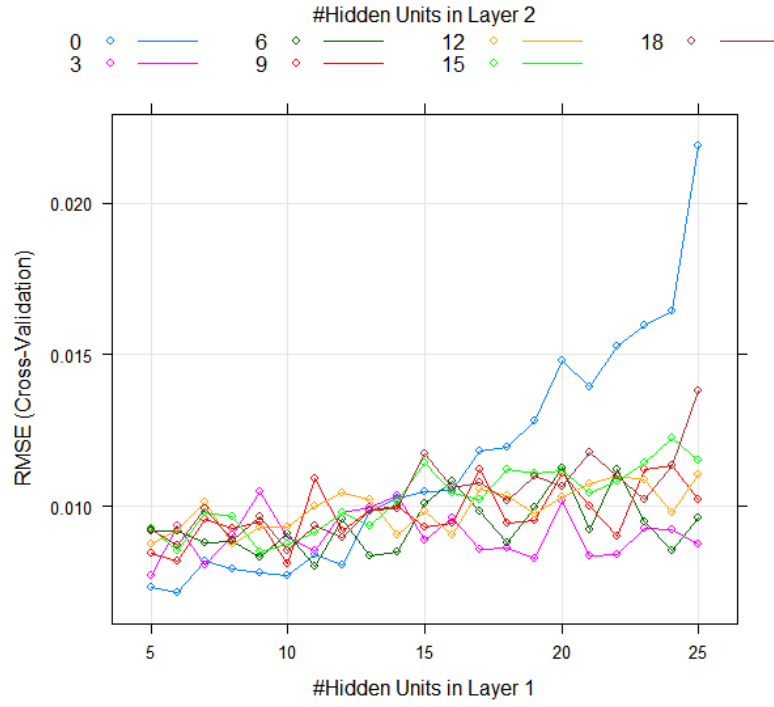


%30'luk veri ise hiçbir şekilde en iyi modelin seçilme sürecine dahil edilmemiş, en iyi model seçildikten sonra ilgili model için test verisi olarak kullanılmıştır.

Orijinal gözlem verisinde *renk* ve *ozelgun* değerleri kategorik verilerdir ve metin bilgisi içermektedirler. Yapay sinir ağları sadece rakamsal ve devamlı verilerle çalışabilmektedir. Bu nedenle kategorik değişkenlerin modele verilmeden önce bir dönüştürme işleminden geçmesi gerekmektedir. Bunun için R programında kullanılan "*model.matrix*" fonksiyonu çalıştırılmıştır. Bu fonksiyona göre her bir kategorik değişken için n-1 değişken ve bir adet kukla değişken tanımlanmaktadır. İlgili kategorik değişkende bulunan tüm seviyeler için oluşturulan her bir kukla değişken 0 ya da 1 değerini alabilir. Her bir satır için bu kukla değişkenlerden biri 1 değerini almış ise diğer tüm kukla değişkenler 0 değerini almak zorundadır.

Yapay sinir ağı çalışma yapısı gereği girdi verilerinin büyüklüklerini dikkate almaktadır. Bu nedenle büyük verilerin gürültü oluşturmaması ve farklı birimlerde olan verilerin tek bir birime dönüştürülmesi amacıyla veride normalizasyon yapılmıştır. Normalizasyon işlemi sadece numerik değişkenlere uygulanmış ve normalizasyon yöntemi olarak min-max normalizasyonu kullanılmıştır.

En uygun yapay sinir ağı modelini bulmak için eşik değeri 0,01 olarak bırakılmış, 1 ve 2 gizli katmanlı ağ modeli çalıştırılmıştır. Eşik değeri model sonucunda elde edilen hata değerindeki değişimin %1'den az olması durumunda optimizasyonu durdurmak için kullanılmıştır. Veri seti olarak *dbr* ürününe ait veriler kullanılmıştır. Satış değerinin tahmin edilmesinden dolayı, sonuçların negatif olmasını önlemek amacıyla sigmoid-lojistik aktivasyon fonksiyonu kullanılmıştır. 1. gizli katmanda bulunan sinir hücreleri 5'ten 25'e kadar olacak şekilde, 2. gizli katmanda bulunan sinir hücreleri 0'dan 20'ye kadar üçerli artacak şekilde ayarlanmış ve yapay sinir ağı modeli her bir kombinasyon için çalıştırılmıştır.



Şekil 4.2. YSA için denenen ağ kombinasyonları ve RMSE performansları.

RMSE hata ölçütüne göre en iyi sonucu veren ağ yapısı 1. gizli katmanda 6 adet yapay sinir hücresi ve 2. gizli katmanda ise 0 adet yapay sinir hücresi olarak elde edilmiştir. Denenen tüm ağların RMSE performansı Şekil 4.2’de verildiği gibidir. Denenen tüm ağlardan bazıları için elde edilen performans değerleri ise Çizelge 4.2’de verilmiştir.

Çizelge 4.2. YSA için denenen bazı ağ kombinasyonları ve performansları.

Gizli Katman 1	Gizli Katman 2	RMSE	R <sup>2</sup>	MAE	Gizli Katman 1	Gizli Katman 2	RMSE	R <sup>2</sup>	MAE
5	0	0,0073	0,9955	0,0051	15	12	0,0098	0,9912	0,0070
5	3	0,0077	0,9952	0,0041	15	15	0,0114	0,9905	0,0065
5	6	0,0092	0,9928	0,0059	15	18	0,0117	0,9886	0,0076
5	9	0,0085	0,9940	0,0052	16	0	0,0105	0,9905	0,0075
5	12	0,0087	0,9935	0,0055	16	3	0,0096	0,9931	0,0056
5	15	0,0093	0,9926	0,0057	16	6	0,0108	0,9903	0,0065
5	18	0,0092	0,9931	0,0061	16	9	0,0094	0,9927	0,0066
<b>6</b>	<b>0</b>	<b>0,0071</b>	<b>0,9957</b>	0,0046	16	12	0,0091	0,9929	0,0065
6	3	0,0093	0,9933	0,0047	16	15	0,0104	0,9906	0,0073
6	6	0,0092	0,9924	0,0053	16	18	0,0106	0,9908	0,0072
6	9	0,0082	0,9948	0,0053	17	0	0,0118	0,9879	0,0085
6	12	0,0092	0,9930	0,0061	17	3	0,0086	0,9937	0,0052
6	15	0,0085	0,9940	0,0056	17	6	0,0098	0,9922	0,0066
6	18	0,0087	0,9937	0,0053	17	9	0,0112	0,9892	0,0075


Çizelge 4.2. (devam ediyor).

Gizli Katman 1	Gizli Katman 2	RMSE	R <sup>2</sup>	MAE	Gizli Katman 1	Gizli Katman 2	RMSE	R <sup>2</sup>	MAE
7	0	0,0082	0,9943	0,0052	17	12	0,0106	0,9910	0,0070
7	3	0,0080	0,9945	0,0049	17	15	0,0102	0,9908	0,0068
7	6	0,0088	0,9934	0,0051	17	18	0,0108	0,9905	0,0072
7	9	0,0096	0,9923	0,0059	18	0	0,0120	0,9876	0,0086
7	12	0,0101	0,9924	0,0059	18	3	0,0086	0,9944	0,0053
7	15	0,0098	0,9924	0,0061	18	6	0,0088	0,9940	0,0054
7	18	0,0099	0,9920	0,0061	18	9	0,0095	0,9928	0,0062
8	0	0,0079	0,9952	0,0053	18	12	0,0104	0,9916	0,0071
8	3	0,0090	0,9938	0,0050	18	15	0,0112	0,9896	0,0075
8	6	0,0088	0,9938	0,0056	18	18	0,0102	0,9909	0,0072
8	9	0,0093	0,9929	0,0060	19	0	0,0128	0,9865	0,0096
8	12	0,0087	0,9933	0,0058	19	3	0,0083	0,9944	0,0049
8	15	0,0097	0,9920	0,0060	19	6	0,0100	0,9920	0,0057


#### 4.3.2.1. Birleştirilmiş Veri Seti İçin YSA Tahmin Uygulaması - Renk Detaylı

En iyi performansı veren ağ yapısı tüm ürünlerin yer aldığı veri setine uygulanmıştır. Oluşan yapay sinir ağı yapısı Şekil 4.3'te verilmiştir.

Yapay sinir ağının sonuçları normalize verildiği için önce normal veri haline getirilip daha sonra tahmin işlemi yapılmıştır. Şekil 4.4'te tüm ürünlerin gözlem değerleri ile YSA'nın tahmin sonuçları grafiği verilmiştir.



Şekil 4.4. Birleştirilmiş veri için renk detaylı gözlem değerleri ve YSA tahmin değerleri.




Şekil 4.3. Elde edilen renk detaylı 1 gizli katmanlı yapay sinir ağı modeli.

Tüm ürünlerin yer aldığı veri seti için elde edilen performans değerleri ise Çizelge 4.3'te verilmiştir.

Çizelge 4.3. Birleştirilmiş veri seti için renk detaylı YSA performansı.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
Birleştirilmiş_YSA	111,7553	0,9965	12489,24	68,5764

Şekil 4.5'te ise test için ayrılan verinin ilk 200 satırı için gözlem ve YSA tahmin değerleri arasındaki ilişki grafiği verilmiştir.

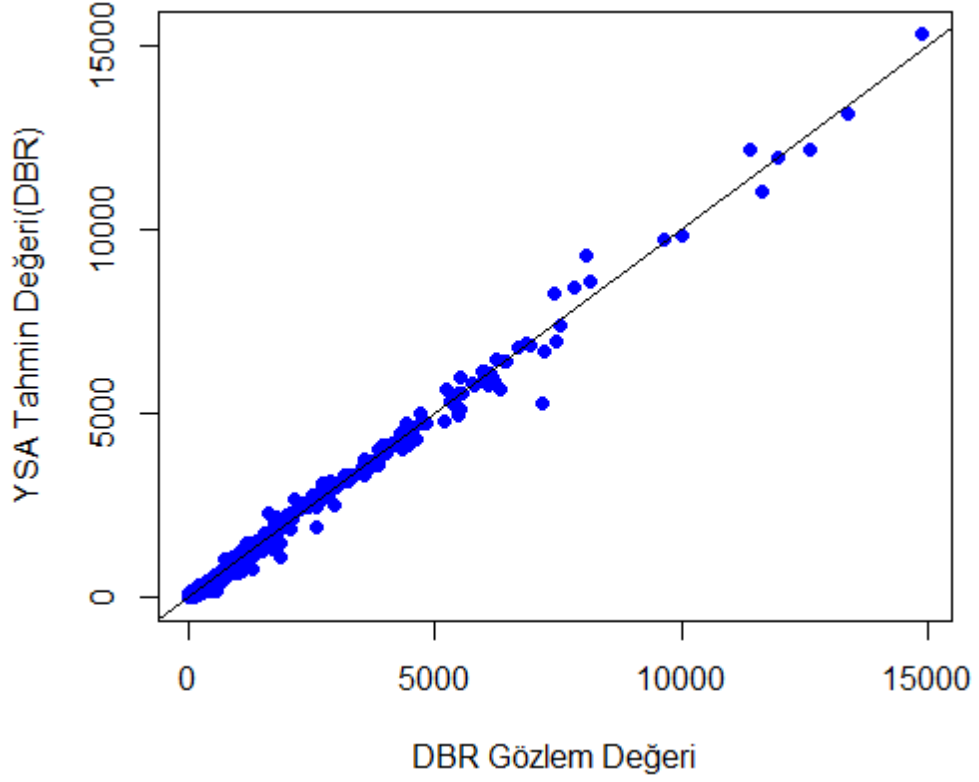


Şekil 4.5. İlk 200 test verisi için renk detaylı gözlem ve YSA tahmin değeri.

#### 4.3.2.2. DBR Ürünü İçin YSA Tahmin Uygulaması - Renk Detaylı

DBR ürünü için 1 gizli katman ve 6 gizli sinir hücresine sahip YSA modeli kurulmuştur. Ağın görseli Şekil 4.6'da verilmiştir.

Yapay sinir ağının sonuçları normalize verildiği için önce normal veri haline getirilip daha sonra tahmin işlemi yapılmıştır. Şekil 4.7’de DBR ürününün gözlem değerleri ile YSA’nın tahmin sonuçları grafiği verilmiştir.



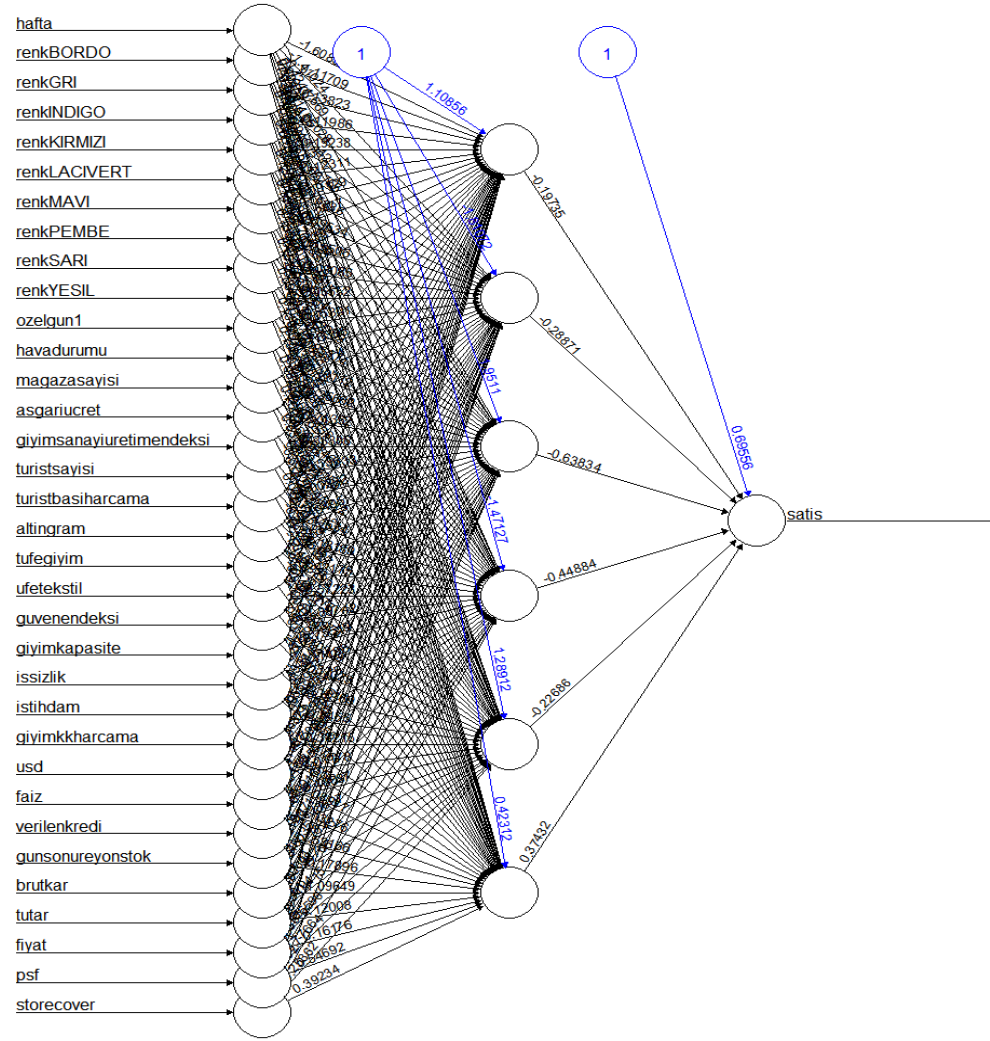
Şekil 4.7. DBR için renk detaylı gözlem değerleri ve YSA tahmin değerleri.

DBR ürünü için kurulan ve çalıştırılan YSA modeli sonucu elde edilen performans değerleri ise Çizelge 4.4’te verilmiştir.

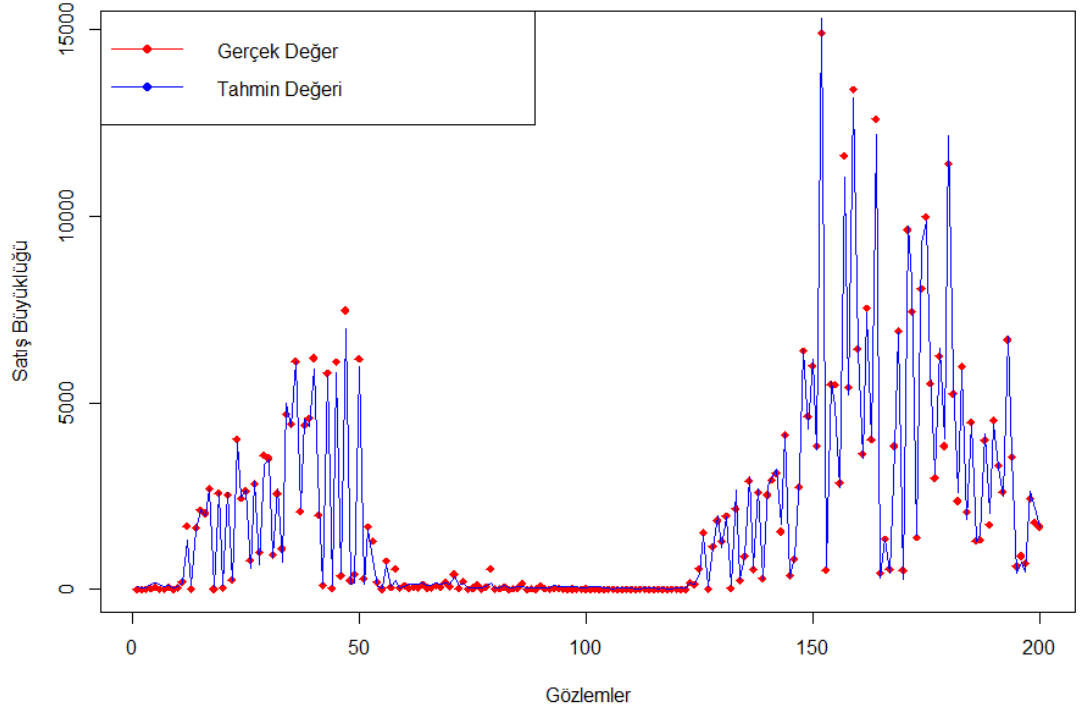
Çizelge 4.4. DBR ürünü renk detaylı veri seti için YSA performansı.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
DBR_YSA	186,704	0,9934	34858,37	104,6364

Şekil 4.8’de ise test verisinde bulunan ilk 200 veri için gözlem ve satış değerleri verilmiştir.



Şekil 4.6. DBR ürünü için renk detaylı kurulan yapay sinir ağı modeli.



Şekil 4.8. DBR ürünü ilk 200 veri için renk detaylı gözlem ve YSA tahmin değerleri.

#### 4.3.2.3. Tüm Ürünler için YSA Tahmin Sonuçları - Renk Detaylı

Bölüm 4.3.2.1 ve 4.3.2.2’de bahsedildiği gibi 1 gizli katmanlı ve 6 yapay sinir hücresine sahip YSA modeli kurulmuş ve tüm ürünler için tek tek çalıştırılmıştır. Elde edilen performans değerleri Çizelge 4.5’te verilmiştir.

Çizelge 4.5’te yer alan sonuçlar karşılaştırma kolaylığı olması açısından normalize edilmiş ve Şekil 4.9’daki grafik çizilmiştir.


Çizelge 4.5. Tüm ürünler için renk detaylı YSA performansları.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
Birleştirilmiş _YSA	111,7553	0,9965	12489,24	68,5764
DBR_YSA	186,7040	0,9934	34858,37	104,6364
CNS_YSA	165,3789	0,9868	27350,20	100,6159
CTY_YSA	127,1884	0,9844	16176,89	80,5952



Çizelge 4.5. (devam ediyor).

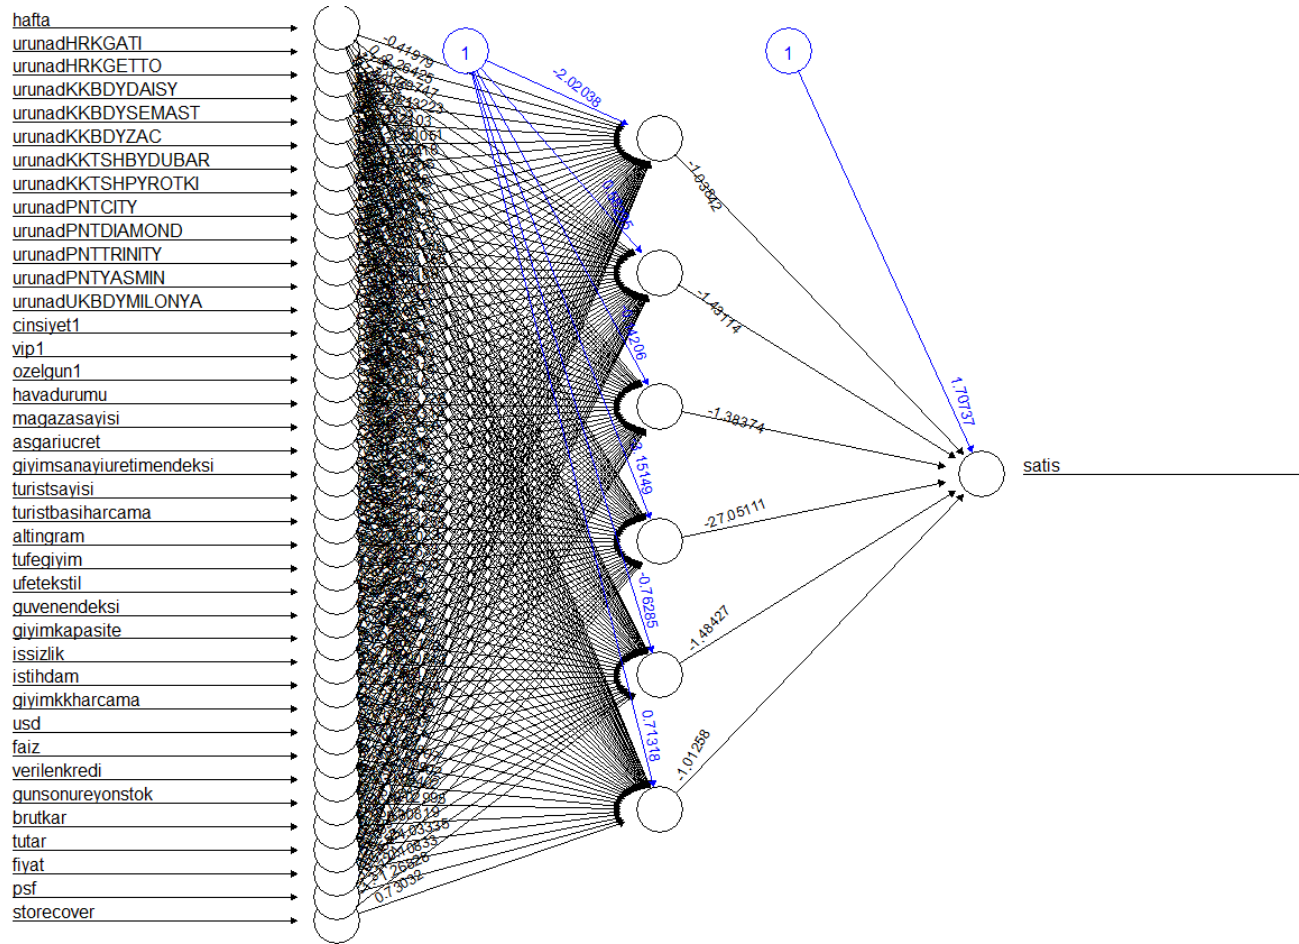
Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
DSY_YSA	202,7883	0,9821	41123,09	67,7779
DMD_YSA	223,8816	0,9845	50122,96	146,9775
GTI_YSA	77,9815	0,9909	6081,12	46,2708
GTT_YSA	51,5636	0,9748	2658,80	25,2369
MLN_YSA	143,0414	0,9926	20460,86	90,2019
RTK_YSA	203,0322	0,9945	41222,05	89,3652
SMT_YSA	223,2509	0,9852	49840,97	136,7205
TNT_YSA	150,8304	0,9926	22749,81	97,3050
YSM_YSA	199,9063	0,9796	39962,51	135,2517
ZCA_YSA	162,2556	0,9932	26326,88	87,8452



Şekil 4.9. Tüm tahminler için normalize edilmiş renk detaylı YSA performans verileri.

#### 4.3.2.4. Birleştirilmiş Veri Seti İçin YSA Tahmin Uygulaması – Renk Detaysız

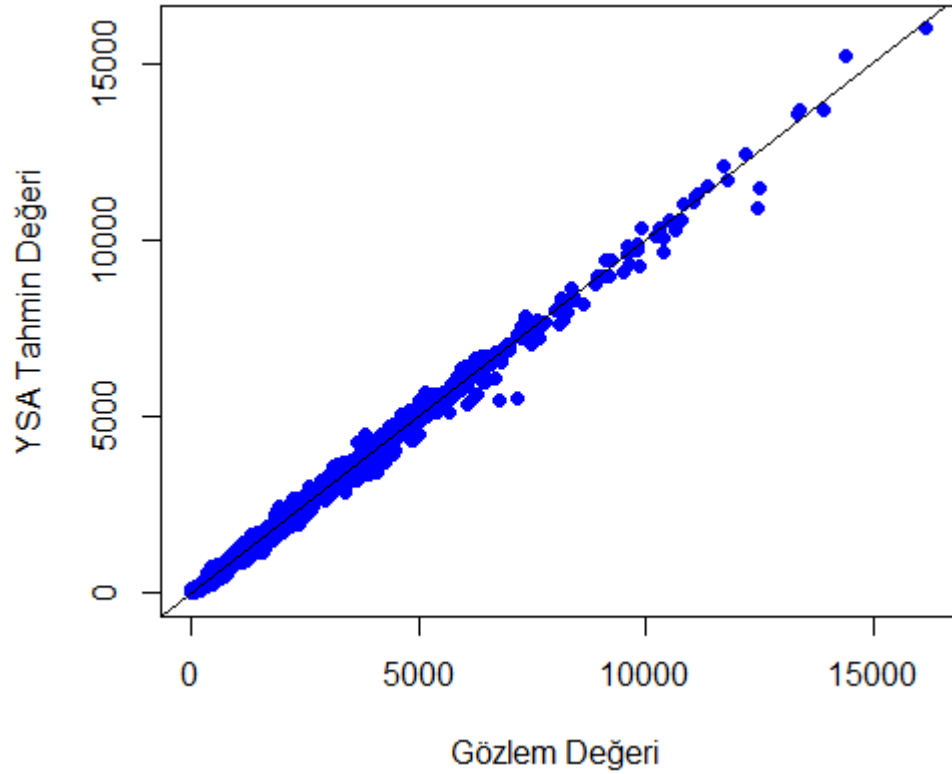
Veriye, model detayında eklenen renk bağımsız değişkeninin ürün satışlarının tahminine etkisini görmek amacıyla bu değişken veriden çıkarılmıştır. Renk değişkeni kategorik bir değişken olduğu için, bu değişkene bağlı olarak oluşturulan



Şekil 4.10. Elde edilen renk detaysız 1 gizli katmanlı yapay sinir ağı modeli.

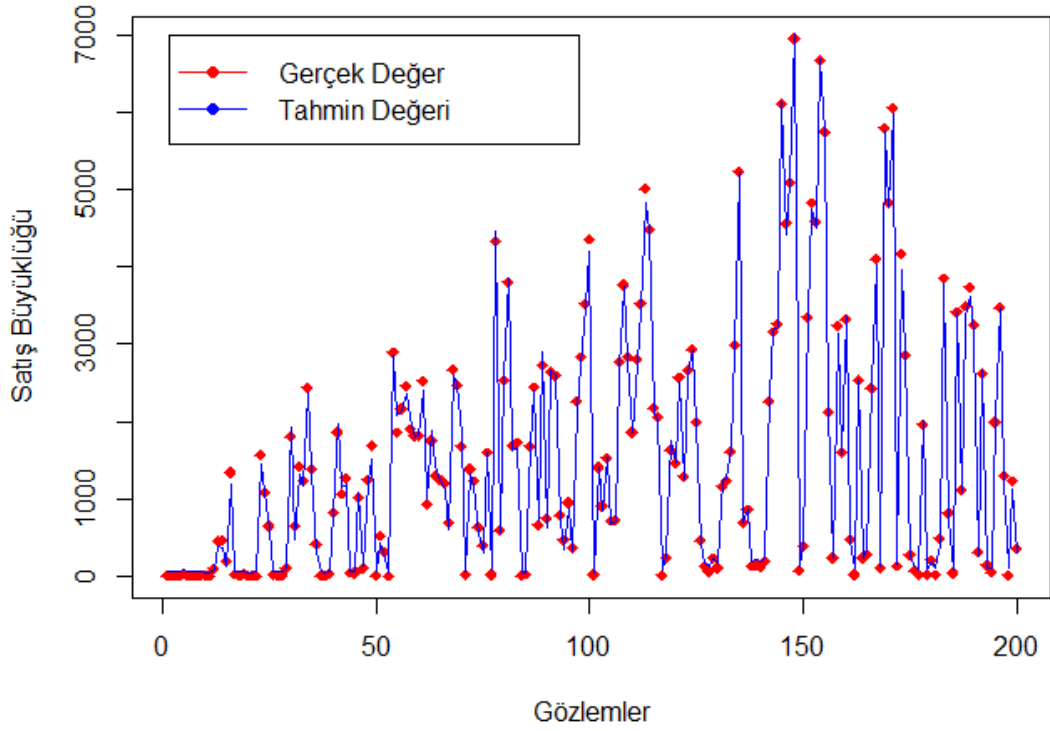
kukla deęişkenlerde YSA girdi katmanından çıkarılacağı için oluşturulan sinir aęının yapısı Şekil 4.10'daki gibi olmuştur.

YSA'da girdi olarak kullanılan veriler normalize olarak kullanılmıştı, bu nedenle normal dönüşüm işlemi uygulanarak veri orijinal formatına çevrilmiş ve tahmin işlemi yapılmıştır. Şekil 4.11'de YSA'nın tahmin sonuçları ile gözlem deęerleri arasındaki ilişki verilmiştir.



Şekil 4.11. Birleştirilmiş veri için renk detaysız gözlem deęerleri ve YSA tahmin deęerleri.

Şekil 4.12'de test için ayrılan verinin ilk 200 satırı için gözlem deęerleri ve YSA tahmin deęerlerini gösteren grafik verilmiştir.



Şekil 4.12. İlk 200 test verisi için renk detaysız gözlem değerleri ve YSA tahmin değeri.

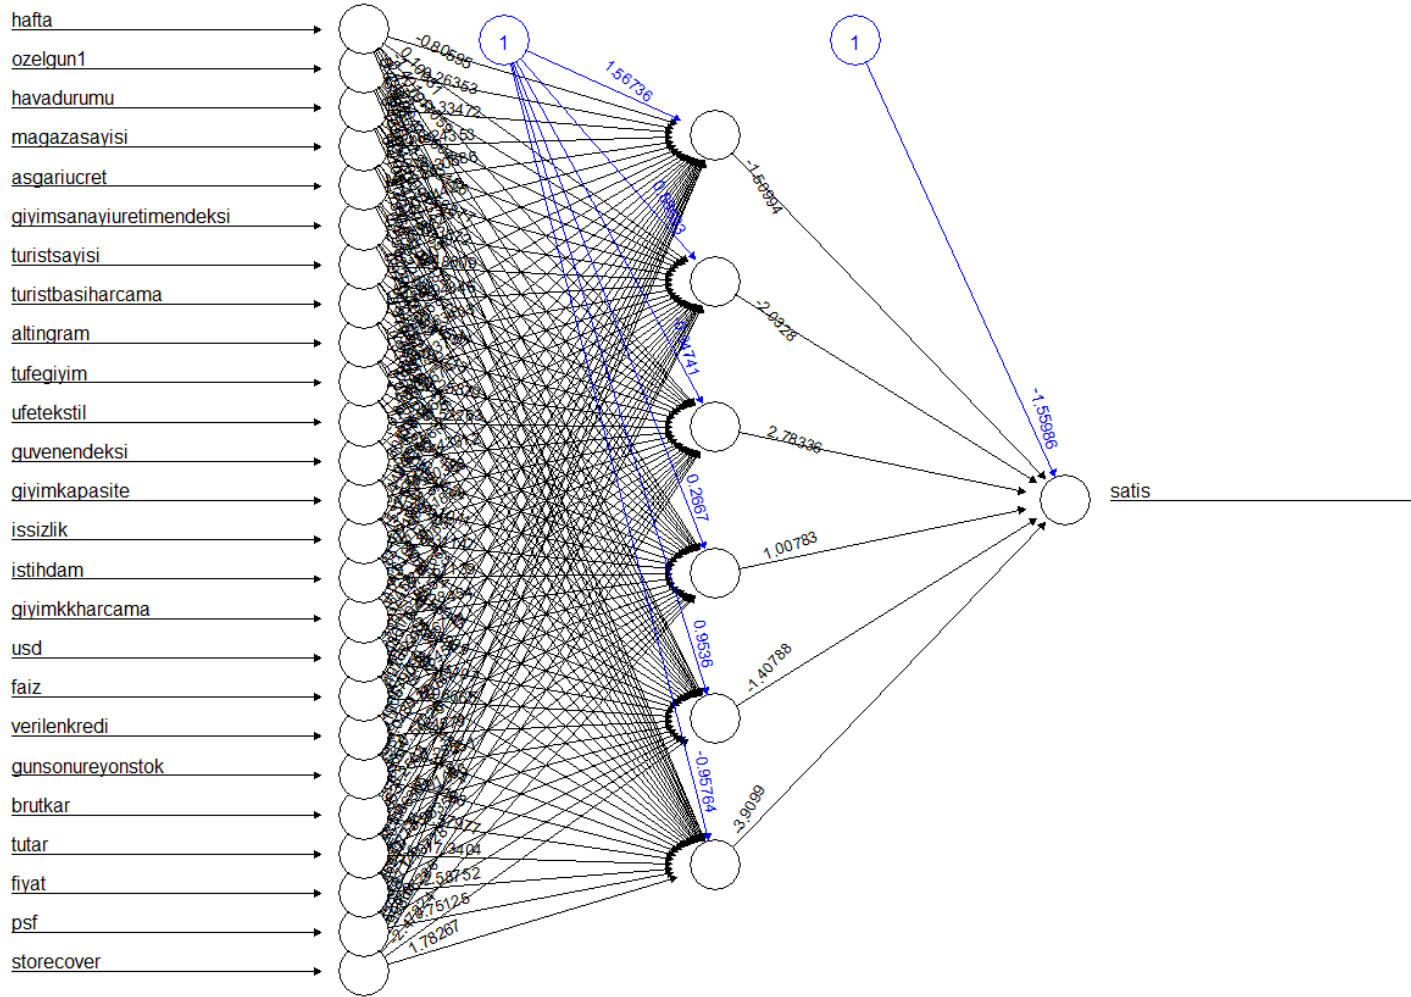
Çizelge 4.6’da tüm ürünlerin yer aldığı renk detaysız veri seti için YSA’nın performans değerleri verilmiştir.

Çizelge 4.6. Tüm veri seti için renk detaysız YSA performansı.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
Birleştirilmiş_ Renksiz_YSA	110,5075	0,9966	12211,91	66,5477


#### 4.3.2.5. DBR Ürünü İçin YSA Tahmin Uygulaması – Renk Detaysız

DBR ürünü için 1 gizli katman ve 6 gizli sinir hücrelerine sahip YSA modeli renk detaysız veri üzerinden kurulmuştur. Ağın görseli Şekil 4.13’de verilmiştir.



Şekil 4.13. DBR ürünü için renk detaysız kurulan YSA modeli.

YSA'nın çıktıları normalize versiyondan orijinal formata çevrildikten sonra tahmin performansı gözlemlenmiştir. DBR ürününün renk detaysız verisi için gözlem değeri ve YSA tahmin sonuçları ilişki grafiği Şekil 4.14'te verilmiştir.




Şekil 4.14. DBR için renk detaysız gözlem ve YSA tahmin değerleri.

DBR ürünü için renk detaysız veri üzerinden çalıştırılan YSA modeli sonucu elde edilen performans değerleri Çizelge 4.7'de verilmiştir.

Çizelge 4.7. DBR ürünü renk detaysız veri seti için YSA performansı.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
DBR_Renksiz_ YSA	247,0299	0,9888	61023,75	131,0824

Şekil 4.15'te ise test verisinde bulunan ilk 200 veri için gözlem ve satış değerleri verilmiştir.



Şekil 4.15. DBR ürünü ilk 200 veri için renk detaysız gözlem ve YSA tahmin değerleri.

#### 4.3.2.6. Tüm Ürünler için YSA Tahmin Sonuçları – Renk Detaysız


Önceki bölümlerde bahsedildiği gibi renk detaysız veri üzerinden 1 gizli katmanlı ve 6 yapay sinir hücresine sahip YSA modeli kurulmuş ve tüm ürünler için tek tek çalıştırılmıştır. Elde edilen performans değerleri Çizelge 4.8’te verilmiştir.

Çizelge 4.8’de yer alan sonuçlar karşılaştırma kolaylığı olması açısından normalize edilmiş ve Şekil 4.16’daki grafik çizilmiştir.

Çizelge 4.8. Tüm ürünler için renk detaysız YSA performansları.

<b>Model Adı</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>MSE</b>	<b>MAE</b>
Birleştirilmiş_ Renksiz_ YSA	110,5075	0,9966	12211,91	66,5477
DBR_Renksiz_ YSA	247,0299	0,9888	61023,75	131,0824
CNS_Renksiz_ YSA	201,5860	0,9800	40636,93	108,9024
CTY_Renksiz_ YSA	97,5920	0,9903	9524,205	69,7986
DSY_Renksiz_ YSA	198,4971	0,9829	39401,11	65,8424
DMD_Renksiz_ YSA	222,7913	0,9842	49635,98	148,6512
GTI_Renksiz_ YSA	63,8973	0,9940	4082,867	42,3083
GTT_Renksiz_ YSA	34,0807	0,9902	1161,491	25,3844
MLN_Renksiz_ YSA	121,4877	0,9947	14759,26	71,5593
RTK_Renksiz_ YSA	164,3412	0,9964	27008,04	80,2580
SMT_Renksiz_ YSA	208,9831	0,9868	43673,93	137,3151
TNT_Renksiz_ YSA	114,1361	0,9958	13027,05	78,1415
YSM_Renksiz_ YSA	244,0114	0,9683	59541,54	176,4304
ZCA_Renksiz_ YSA	144,0030	0,9946	20736,88	72,0925






Şekil 4.16. Tüm tahminler için normalize edilmiş renk detaysız YSA performans verileri.

#### 4.3.3. Destek Vektör Makineleri Tahmin Uygulaması – Renk Detaylı

Destek vektör makineleri uygulamasında R Studio programı ve R dili kullanılarak yazılan algoritma ile analiz gerçekleştirilmiştir.

Destek vektör makinelerinin performansını etkileyen iki parametre mevcuttur. Bunlar sigma değeri ve C ile ifade edilen ceza puanı değeridir. Optimum modeli bulabilmek için sigma değeri 0,1 ile 1 arasında her iterasyonda 0,1 birim artacak şekilde, C değeri ise 1 ile 10 arasında ikişerli artacak şekilde tanımlanmıştır. Modele verilen verilerin %70'i eğitim verisi olarak tanımlanmış, bu veriler de en iyi modelin seçimi aşamasında çapraz doğrulama yapılarak performans test edilmiştir. Geriye kalan %30'luk veri ise en iyi modelin performansını ölçmek için test verisi olarak kullanılmıştır. Regresyon modeli kullanıldığı için radial kernel kullanılmıştır.

Yapay sinir ağlarından farklı olarak destek vektör makinelerinde veriler önceden normalize edilmemiştir, kullanılan paket içerisinde normalize edilme işlemi yapılmıştır ve kategorik veriler doğrudan modele verilmiştir, kukla değişkenlerin oluşturulmasına bu yöntem için gerek yoktur.



Şekil 4.17. DVM için tüm parametre kombinasyonları ve RMSE performansları.

RMSE hata ölçütüne göre DVM için en iyi sonucu veren parametreler sigma değeri 0,1 ve C değeri ise 7 olarak hesaplanmıştır. Denenen tüm parametreler için RMSE performansı Şekil 4.17’de verildiği gibidir. Denenen tüm parametreler için elde edilen performans değerleri ise Çizelge 4.9’da verilmiştir.

Çizelge 4.9. DVM için tüm parametreler ve performansları.

Sigma	C	RMSE	R <sup>2</sup>	MAE	Sigma	C	RMSE	R <sup>2</sup>	MAE
0,1	1	672,4469	0,9312	274,1538	0,6	1	1731,8415	0,6237	726,7639
0,1	3	570,5969	0,9486	254,7998	0,6	3	1500,9674	0,7110	677,6791
0,1	5	561,8315	0,9497	253,9227	0,6	5	1459,5104	0,7263	672,6272
<b>0,1</b>	<b>7</b>	<b>559,2119</b>	<b>0,9499</b>	254,0798	0,6	7	1456,9013	0,7273	673,2211
0,1	9	559,2119	0,9499	254,0798	0,6	9	1456,7705	0,7273	673,5938
0,2	1	1136,9837	0,8395	424,7185	0,7	1	1786,8153	0,5998	771,7521
0,2	3	894,9736	0,8904	374,8966	0,7	3	1572,5022	0,6821	726,6546
0,2	5	877,3247	0,8943	373,2732	0,7	5	1532,4248	0,6979	722,5251
0,2	7	876,4846	0,8944	373,8986	0,7	7	1529,4149	0,6991	723,1706
0,2	9	876,1036	0,8945	373,9903	0,7	9	1529,2684	0,6991	723,5463

Çizelge 4.9. (devam ediyor).

<b>Sigma</b>	<b>C</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>MAE</b>	<b>Sigma</b>	<b>C</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>MAE</b>
0,3	1	1420,0204	0,7501	533,9232	0,8	1	1832,7006	0,5799	812,9978
0,3	3	1121,9716	0,8356	469,6353	0,8	3	1630,7509	0,6575	770,7994
0,3	5	1101,1359	0,8418	467,6648	0,8	5	1593,3738	0,6729	767,8475
0,3	7	1100,4797	0,8419	468,3143	0,8	7	1590,3869	0,6742	768,5831
0,3	9	1100,3133	0,8420	468,5694	0,8	9	1590,2412	0,6742	768,9499
0,4	1	1567,9514	0,6925	613,4521	0,9	1	1871,9784	0,5623	849,5527
0,4	3	1287,9725	0,7874	554,2971	0,9	3	1679,6636	0,6361	810,1083
0,4	5	1256,4300	0,7969	549,9888	0,9	5	1645,2646	0,6505	808,2359
0,4	7	1254,9544	0,7973	550,5650	0,9	7	1642,5642	0,6517	809,1741
0,4	9	1254,8302	0,7973	550,8590	0,9	9	1642,4026	0,6517	809,5651
0,5	1	1662,4549	0,6534	674,2100	1	1	1906,6630	0,5464	882,7520
0,5	3	1409,1504	0,7460	622,0880	1	3	1722,0369	0,6169	846,0451
0,5	5	1370,1741	0,7589	616,9003	1	5	1690,5093	0,6301	845,0778
0,5	7	1368,2797	0,7595	617,4899	1	7	1688,1585	0,6312	846,1869
0,5	9	1368,1452	0,7595	617,8235	1	9	1687,9936	0,6312	846,5671


#### 4.3.3.1. Birleştirilmiş Veri Seti İçin DVM Tahmin Uygulaması – Renk Detaylı

En iyi performansı veren parametreler tüm ürünlerin yer aldığı veri setine uygulanmıştır. Şekil 4.18’de tüm ürünlerin gözlem değerleri ile DVM’nin tahmin sonuçları grafiği verilmiştir.


Birleştirilmiş veri seti için elde edilen performans değerleri ise Çizelge 4.10’te verilmiştir. Şekil 4.19’de ise test için ayrılan verinin ilk 200 satırı için gözlem ve DVM tahmin değerleri arasındaki ilişki grafiği verilmiştir.

Çizelge 4.10. Birleştirilmiş veri seti için renk detaylı DVM performansı.

<b>Model Adı</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>MSE</b>	<b>MAE</b>
Bileştirilmiş_DVM	141,2274	0,9944	19945,19	98,8338



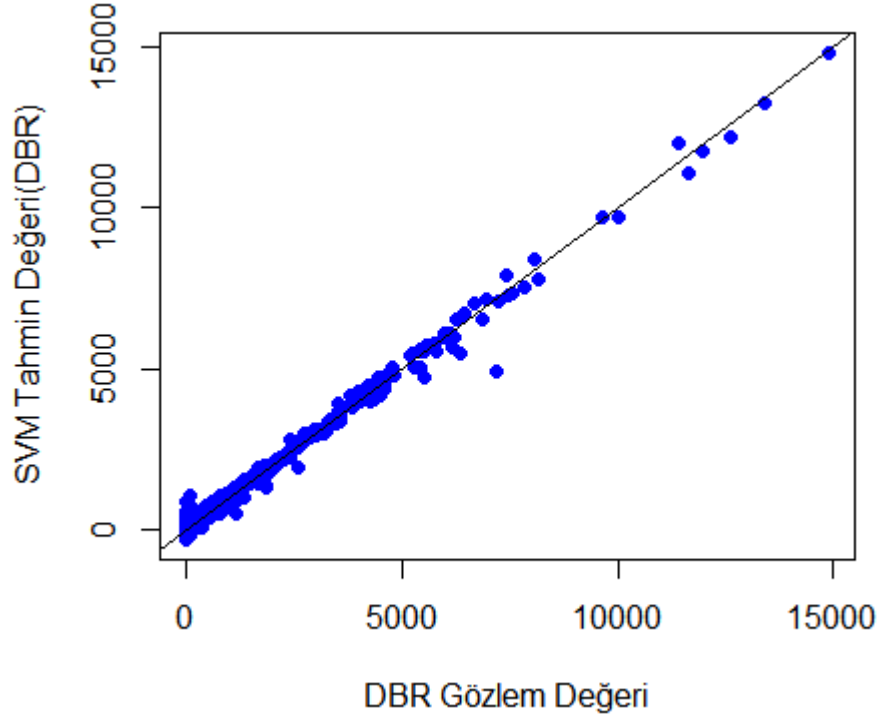
Şekil 4.18. Birleştirilmiş veri için renk detaylı gözlem değerleri ve DVM tahmin değerleri.



Şekil 4.19. İlk 200 test verisi için renk detaylı gözlem ve DVM tahmin değeri.

#### 4.3.3.2. DBR Ürünü İçin DVM Tahmin Uygulaması – Renk Detaylı

DBR ürünü için sigma değeri 0,1 ve C ceza puanı 7 olan DVM modeli kurulmuştur. Şekil 4.20’de DBR ürününün gözlem değeri ile DVM’nin tahmin sonuçları grafiği verilmiştir.




Şekil 4.20. DBR ürünü için renk detaylı gözlem ve DVM tahmin değerleri.

DBR ürünü için kurulan ve çalıştırılan DVM modeli sonucu elde edilen performans değerleri ise Çizelge 4.11’te verilmiştir.

Çizelge 4.11. DBR ürünü renk detaylı veri seti için DVM performansı.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
DBR_DVM	214.8514	0.9917	46161.14	150.641

Şekil 4.21’de ise DBR ürününün test için ayrılan verisinin ilk 200 satırı için gözlem ve DVM tahmin değerleri arasındaki ilişki grafiği verilmiştir.



Şekil 4.21. DBR ürünü ilk 200 veri için renk detaylı gözlem ve DVM tahmin değerleri.

#### 4.3.3.3. Tüm Ürünler için DVM Tahmin Sonuçları – Renk Detaylı

Bölüm 4.3.3.1 ve 4.3.3.2’de bahsedildiği gibi 0,1 sigma değeri ve 7 ceza puanına sahip DVM modeli kurulmuş ve tüm ürünler için tek tek çalıştırılmıştır. Elde edilen performans değerleri Çizelge 4.12’da verilmiştir.


Çizelge 4.12. Tüm ürünler için renk detaylı DVM performansları.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
Birleştirilmiş _DVM	141,2274	0,9944	19945,19	98,8338
DBR_DVM	214,8514	0,9917	46161,14	150,6410

Çizelge 4.12. (devam ediyor).

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
CNS_DVM	150,3100	0,9895	22593,11	103,1847
CTY_DVM	94,8160	0,9911	8990,07	69,5376
DSY_DVM	245,7346	0,9747	60385,49	101,8023
DMD_DVM	238,7557	0,9837	57004,27	162,9903
GTI_DVM	72,8746	0,9926	5310,71	53,9331
GTT_DVM	75,1014	0,9515	5640,21	42,3022
MLN_DVM	185,3390	0,9879	34350,53	115,5948
RTK_DVM	220,9593	0,9937	48823,00	163,6835
SMT_DVM	190,3810	0,9900	36244,91	123,8490
TNT_DVM	187,0412	0,9888	34984,40	134,7333
YSM_DVM	180,3085	0,9823	32511,17	132,5861
ZCA_DVM	154,7722	0,9941	23954,44	113,2650


Çizelge 4.12’te yer alan sonuçlar karşılaştırma kolaylığı olması açısından normalize edilmiş ve Şekil 4.22’deki grafik çizilmiştir.



Şekil 4.22. Tüm tahminler için normalize edilmiş renk detaylı DVM performans verileri.

#### 4.3.3.4. Birleştirilmiş Veri Seti İçin DVM Tahmin Uygulaması – Renk Detaysız

En iyi performansı veren parametreler tüm ürünlerin yer aldığı renk detaysız veri setine uygulanmıştır. Şekil 4.23’de tüm ürünlerin gözlem değerleri ile DVM’nin tahmin sonuçları grafiği verilmiştir.



Şekil 4.23. Birleştirilmiş veri için renk detaysız gözlem değerleri ve DVM tahmin değerleri.

Tüm ürünlerin yer aldığı veri seti için elde edilen performans değerleri ise Çizelge 4.13’te verilmiştir.


Çizelge 4.13. Tüm veri seti için renk detaysız DVM performansı.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
Birleştirilmiş_ Renksiz_ DVM	147,9799	0,9940	21898,04	97,9604

Şekil 4.24’de ise test için ayrılan verinin ilk 200 satırı için gözlem ve DVM tahmin değerleri arasındaki ilişki grafiği verilmiştir.




### Tüm Veriler için SVM Tahmini - Renk Detaysız



Şekil 4.24. İlk 200 test verisi için renk detaysız gözlem değerleri ve DVM tahmin değeri.

#### 4.3.3.5. DBR Ürünü İçin DVM Tahmin Uygulaması – Renk Detaysız

DBR ürünü için sigma değeri 0,1 ve C ceza puanı 7 olan ve renk detayı içermeyen veri seti için DVM modeli kurulmuştur. Şekil 4.25’de DBR ürününün gözlem değeri ile DVM’nin tahmin sonuçları grafiği verilmiştir.




Şekil 4.25. DBR için renk detaysız gözlem ve DVM tahmin değerleri.

DBR ürünü için kurulan ve çalıştırılan DVM modeli sonucu elde edilen performans değerleri ise Çizelge 4.14’te verilmiştir.

Çizelge 4.14. DBR ürünü renk detaysız veri seti için DVM performansı.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
DBR_Renksiz_ DVM	225,588	0,9911	50889,94	161,1109

Şekil 4.26’da ise DBR ürününün test için ayrılan verisinin ilk 200 satırı için gözlem ve DVM tahmin değerleri arasındaki ilişki grafiği verilmiştir.



Şekil 4.26. DBR ürünü ilk 200 veri için renk detaysız gözlem ve DVM tahmin değeri.

#### 4.3.3.6. Tüm Ürünler için DVM Tahmin Sonuçları – Renk Detaysız

Önceki bölümlerde bahsedildiği gibi 0,1 sigma değeri ve 7 ceza puanına sahip DVM modeli kurulmuş renk detaysız veriler için ve tüm ürünler için tek tek çalıştırılmıştır. Elde edilen performans değerleri Çizelge 4.15’da verilmiştir.


Çizelge 4.15. Tüm ürünler için renk detaysız DVM performansları.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
Birleştirilmiş_ Renksiz_ DVM	166,4352	0,9922	27700,66	111,3351
DBR_Renksiz_ DVM	225,5880	0,9911	50889,94	161,1109

Çizelge 4.15. (devam ediyor).

<b>Model Adı</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>MSE</b>	<b>MAE</b>
CNS_Renksiz_ DVM	162,5657	0,9882	26427,60	109,4726
CTY_Renksiz_ DVM	101,5939	0,9897	10321,33	71,5978
DSY_Renksiz_ DVM	277,9750	0,9681	77270,11	107,4484
DMD_Renksiz_ DVM	249,5465	0,9822	62273,48	169,5204
GTI_Renksiz_ DVM	85,0064	0,9902	7226,08	58,3639
GTT_Renksiz_ DVM	77,6572	0,9476	6030,63	42,6438
MLN_Renksiz_ DVM	200,6894	0,9856	40276,22	121,7172
RTK_Renksiz_ DVM	228,9696	0,9933	52427,07	167,2115
SMT_Renksiz_ DVM	188,8642	0,9905	35669,69	121,4990
TNT_Renksiz_ DVM	192,0092	0,9881	36867,55	141,5668
YSM_Renksiz_ DVM	184,7317	0,9813	34125,81	130,3051
ZCA_Renksiz_ DVM	158,2374	0,9940	25039,06	113,7944

Çizelge 4.15'te yer alan sonuçlar karşılaştırma kolaylığı olması açısından normalize edilmiş ve Şekil 4.27'deki grafik çizilmiştir.



Şekil 4.27. Tüm tahminler için normalize edilmiş renk detaysız DVM performans verileri.

#### 4.3.4. Rastgele Ormanlar Tahmin Uygulaması


Rastgele Ormanlar uygulamasında R Studio programı ve R dili kullanılarak yazılan algoritma ile analiz gerçekleştirilmiştir.

RO yönteminde karar ağacının performansı modelde kullanılan ağaç sayısına, tahmin için kullanılacak değişken (girdi) sayısına, düğüm sayısına ve her bir düğümdeki veri sayısına göre değişebilmektedir. Doğru bir tahmin yapabilmek için bu parametrelerin değişik değerler ile denendiği modeller kurulmuş ve en iyi performansı veren model ile tahmin işlemleri gerçekleştirilmiştir. Ayrıca literatürde yer alan çalışmada düğümde yer alması gereken minimum veri sayısının model performansı üzerinde önemli bir etkisi olmadığı belirtildiği için tüm modellerde nodesize=5 olarak bırakılmıştır [76].

RO modeli kurulurken, modelde değerlendirilecek değişken sayısı (mtry) 2 ile 26 arasında, maksimum düğüm sayısı 10 ile 30 arasında ve maksimum ağaç ise 250, 300, 350, 400, 450, 500, 550, 600, 800, 1000 değerlerini alacak şekilde ayarlanmış ve her bir parametre diğerlerinden etkilenmemesi için, diğer parametreler sabit

bırakılarak çalıştırılmıştır. Model çalıştırılırken tüm verilerin %70'i modele verilmiş, çapraz doğrulama kullanılmış ve veri grubu sayısı 10 olarak kullanılmıştır. Geriye kalan %30'luk veri ise bekletme metodu ile doğrulama yapmak üzere test verisi olarak ayrılmıştır. Veriler normalize edilmemiştir.

İlk olarak her bir ağaca seçilecek değişkenlerin sayısını belirlemek amacıyla model çalıştırılmıştır. 2 ile 26 değişkenin dahil olduğu tüm kombinasyonlar sonucunda RMSE değeri 265,5792 olan 13 değişkenin dahil olduğu model en iyi performansı göstermiştir. Şekil 4.28'de seçilecek değişkenlerin sayısını içeren tüm kombinasyonlar ve RMSE değerleri verilmiştir.



Şekil 4.28. RO için tüm parametre kombinasyonları ve RMSE performansları.

Çizelge 4.16'da ise tüm kombinasyonlar için RMSE değerleri verilmiştir.

Çizelge 4.16. 2 ile 26 değişken için RO performansı.

mtry	RMSE	R <sup>2</sup>	MAE	mtry	RMSE	R <sup>2</sup>	MAE
2	688,5434	0,9467	319,0139	15	271,4259	0,9897	82,3813
3	546,5969	0,9650	231,7410	16	274,2244	0,9896	83,2481
4	452,2962	0,9752	180,8369	17	268,4750	0,9899	80,5556
5	389,6551	0,9811	149,5055	18	271,7602	0,9897	80,1058
6	358,5946	0,9834	129,2229	19	274,7163	0,9893	80,8618
7	331,7264	0,9855	113,9866	20	268,8633	0,9899	78,7811
8	311,4296	0,9868	103,9486	21	271,5449	0,9894	78,7265
9	294,9981	0,9882	97,3658	22	271,5169	0,9895	77,9156
10	281,5095	0,9888	91,9462	23	275,5224	0,9893	79,1255
11	280,5863	0,9892	89,2647	24	272,1636	0,9895	77,8750
12	273,8965	0,9896	86,8433	25	276,4800	0,9890	79,2541
13	<b>265,5792</b>	0,9901	83,5248	26	276,7150	0,9889	79,2467
14	269,7052	0,9899	83,9299				

En uygun değişken sayısı 13 olarak belirlendikten sonra en uygun düğüm sayısını belirlemek için RO modeli 10 ile 30 adet düğüm oluşacak tüm kombinasyonları, her bir ağaçta 13 değişkenin rastgele seçileceği şekilde çalıştırılmıştır. Model sonuçları Çizelge 4.17’de verilmiştir.

Çizelge 4.17. 10 ile 30 düğüm sayısı için RO performansı.

Düğüm Sayısı	RMSE	R <sup>2</sup>	MAE	Düğüm Sayısı	RMSE	R <sup>2</sup>	MAE
10	535,2151	0,9652	247,4873	21	387,0536	0,9818	158,9472
11	534,0228	0,9655	240,2839	22	379,4372	0,9826	156,5323
12	521,7222	0,9665	230,3051	23	378,3540	0,9825	152,0128
13	469,8005	0,9733	203,1818	24	366,4147	0,9835	146,4047
14	429,2992	0,9774	185,1028	25	357,6438	0,9842	142,1111
15	413,5049	0,9795	176,9941	26	349,9974	0,9848	138,9798
16	398,6516	0,9808	172,1841	27	338,6685	0,9859	133,6400

Çizelge 4.17. (devam ediyor).

Düğüm Sayısı	RMSE	R <sup>2</sup>	MAE	Düğüm Sayısı	RMSE	R <sup>2</sup>	MAE
17	394,6594	0,9809	167,5232	28	336,3275	0,9858	131,7721
18	397,1203	0,9807	168,3766	<b>29</b>	<b>331,7566</b>	0,9864	130,0845
19	390,6368	0,9815	163,7368	30	333,9200	0,9861	129,4855
20	390,6061	0,9813	162,8043				

Çalıştırılan model sonucunda en iyi RMSE performansını sağlayan düğüm sayısı 29 olarak belirlenmiştir. Tüm ağaç sayıları için elde edilen performans değerleri Çizelge 4.18’de verilmiştir.

Çizelge 4.18. Çeşitli ağaç sayıları için RO performansı.

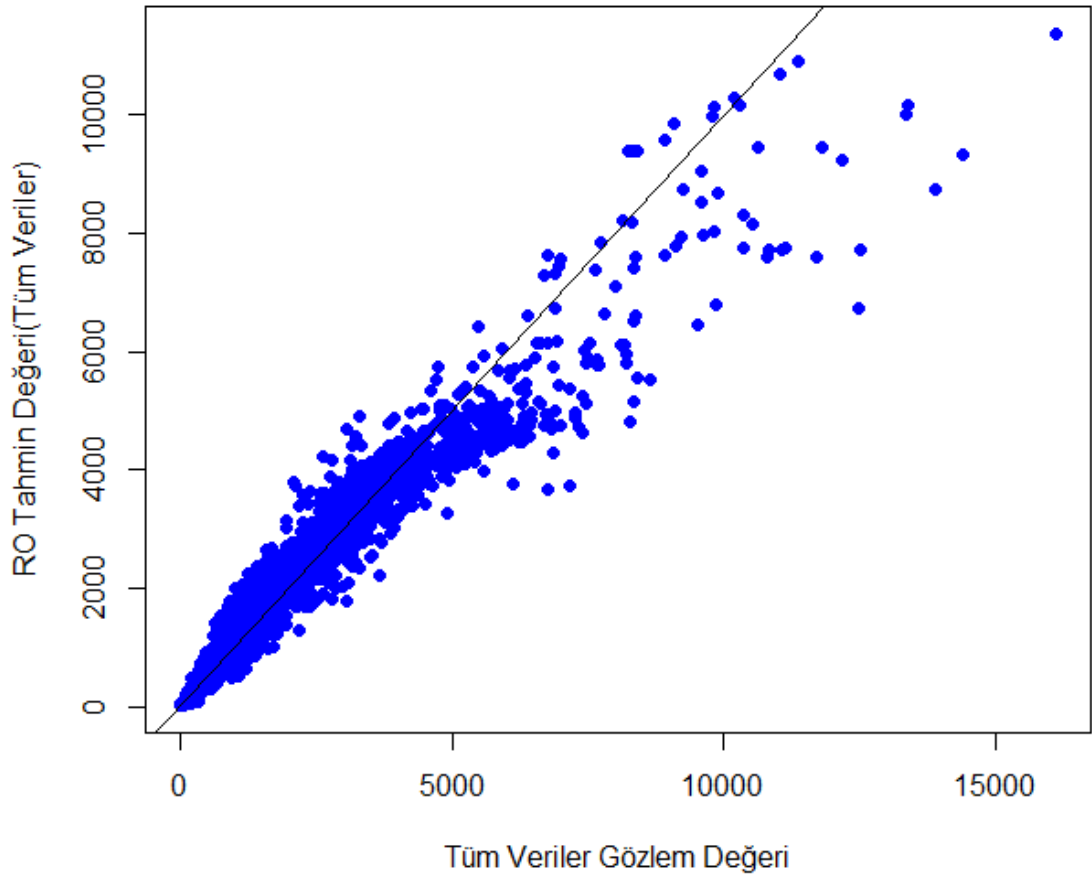
Ağaç Sayısı	RMSE	R <sup>2</sup>	MAE	Ağaç Sayısı	RMSE	R <sup>2</sup>	MAE
250	332,5556	0,9850	127,1369	500	331,3050	0,9852	126,6977
300	331,8685	0,9850	126,9260	<b>550</b>	<b>330,5352</b>	0,9852	126,3491
350	331,7548	0,9851	126,7011	600	331,9991	0,9851	126,5138
400	331,7360	0,9851	126,7416	800	331,0461	0,9852	126,3509
450	331,3297	0,9852	126,6071	1000	322,8556	0,9860	125,1495

Sonuç olarak en iyi performansa sahip olan RO modeli ağaç sayısı 550, düğüm sayısı 29 ve değişken sayısı ise 13 olan model olarak elde edilmiştir.

#### 4.3.4.1. Birleştirilmiş Veri Seti İçin RO Tahmin Uygulaması – Renk Detaylı

Bir önceki bölümde elde edilen en iyi performansı sağlayan model tüm ürünlerin yer aldığı veri setine uygulanmıştır. Şekil 4.29’da tüm ürünlerin gözlem değerleri ve rastgele ormanlar sonucu tahmin değerleri verilmiştir.





Şekil 4.29. Birleştirilmiş veri için renk detaylı gözlem değerleri ve RO tahmin değerleri.


Tüm ürünlerin yer aldığı veri seti için RO modeli sonucu elde edilen performans değerleri ise Çizelge 4.19’te verilmiştir.

Çizelge 4.19. Tüm veri seti için renk detaylı RO performansı.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
Birleştirilmiş _RO	457,6473	0,9464	209441	206,4542

Şekil 4.30’da da test için ayrılan verinin ilk 200 satırı için gözlem ve RO tahmin sonuçlarının grafiği verilmiştir.


### Tüm Veriler için RO Tahmini



Şekil 4.30. İlk 200 test verisi için renk detaylı gözlem ve RO tahmin değerleri.

RO yöntemini diğer yöntemlerden ayıran en önemli özelliklerden biri de, bu yöntemde değişkenlerin bağımlı değişken üzerindeki etkisini de ölçebiliyor olmamızdır. Şekil 4.31’de tüm verilere uygulanan RO’nun sonucunda elde edilen önem sırası verilmiştir.

### Tüm Ürünler için Değişkenlerin Önem Değeri(RO)




Şekil 4.31. Birleştirilmiş veri için renk detaylı RO sonucunda değişkenlerin önem sırası, a) MSE'ye olan etki sıralaması, b) düğüm saflığı sıralaması.

Şekil 4.31 b'de görüldüğü üzere “node purity” yani düğüm saflığı sıralamasına göre *magazasayisi* değişkeni tüm veri setinin tahmin edildiği modelde en önemli değişken olarak dikkat çekmektedir. Sırasıyla *tutar*, *brutkar*, *psf* (*perakende satış fiyatı*), *urunad*, *gunsonureyonstok* ve diğer değişkenler önem sırasına göre listelenmiştir. Şekil 4.31a' da ise değişkenler MSE üzerinde en fazla etkiye sahip olandan daha az olana doğru sıralanmıştır. Ayrıca model sonucuna göre bağımlı değişkenin %93,35'i bağımsız değişkenlerce açıklanabilmektedir.

#### 4.3.4.2. DBR Ürünü İçin RO Tahmin Uygulaması – Renk Detaylı

DBR ürününe ait veri seti elde edilen modele uygulanmış ve tahmin sonuçları ile gözlem değerleri grafiği Şekil 4.32'de verilmiştir.



Şekil 4.32. DBR ürünü için renk detaylı gözlem ve RO tahmin değerleri.


DBR ürünü için kurulan ve çalıştırılan RO modeli sonucu elde edilen performans değerleri ise Çizelge 4.20’te verilmiştir.

Çizelge 4.20. DBR ürünü renk detaylı veri seti için RO performansı.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
DBR_RO	244,0634	0,9887	59566,96	107,6851


Şekil 4.33’de ise DBR ürününün test için ayrılan verisinin ilk 200 satırı için gözlem ve RO tahmin değerleri arasındaki ilişki grafiği verilmiştir.

### DBR için RO Tahmini



Şekil 4.33. DBR ürünü ilk 200 veri için renk detaylı gözlem değerleri ve RO tahmin değerleri.

### DBR - Değişkenlerin Önem Değeri(RO)



Şekil 4.34. DBR için renk detaylı RO sonucunda elde edilen değişkenlerin önem sırası, a) MSE'ye olan etki sıralaması, b) düğüm saflığı sıralaması.

Şekil 4.34b’de “*node purity*” yani düğüm saflığı sıralamasına göre *tutar* değişkeni tüm veri setinin tahmin edildiği modelde en önemli değişken olarak dikkat çekmektedir. Sırasıyla *brutkar*, *magazasayisi*, *renk* ve diğer değişkenler önem sırasına göre listelenmiştir. Şekil 4.34a’da ise değişkenler MSE üzerinde en fazla etkiye sahip olandan daha az olana doğru sıralanmıştır. *tutar* değişkeni üzerinde meydana gelecek değişiklik MSE’yi %38,59 oranında etkilemektedir. Ayrıca model sonucuna göre bağımlı değişkenin %98,46’sı bağımsız değişkenlerce açıklanabilmektedir.


#### 4.3.4.3. Tüm Ürünler için RO Tahmin Sonuçları – Renk Detaylı

Önceki bölümlerde kurulan rastgele orman modeli tüm ürünler için tek tek çalıştırılmıştır. Elde edilen performans değerleri Çizelge 4.21’de verilmiştir.

Çizelge 4.21. Tüm ürünler için renk detaylı RO performansları.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
Birleştirilmiş_ RO	457,6473	0,9464	209441,00	206,4542
DBR_RO	244,0634	0,9887	59566,96	107,6851
CNS_RO	119,3053	0,9935	14233,75	51,6376
CTY_RO	144,2843	0,9790	20817,95	77,7959
DSY_RO	264,4429	0,9697	69930,06	78,0676
DMD_RO	373,7299	0,9617	139674,00	200,0888
GTI_RO	120,4274	0,9792	14502,76	58,2110
GTT_RO	29,5356	0,9918	872,35	12,7068
MLN_RO	227,9786	0,9810	51974,26	102,0196
RTK_RO	322,8459	0,9882	104229,50	116,4892
SMT_RO	237,3269	0,9830	56324,04	136,7926
TNT_RO	166,5792	0,9910	27748,62	89,6149
YSM_RO	193,4200	0,9805	37411,29	128,7146
ZCA_RO	258,5193	0,9837	66832,23	119,9173

Çizelge 4.21’de yer alan sonuçlar karşılaştırma kolaylığı olması açısından normalize edilmiş ve Şekil 4.35’deki grafik çizilmiştir.



Şekil 4.35. Tüm tahminler için normalize edilmiş renk detaylı RO performans verileri.


#### 4.3.4.4. Birleştirilmiş Veri Seti İçin RO Tahmin Uygulaması – Renk Detaysız

Renk detayının çıkarıldığı ve tüm ürünlerin yer aldığı veri seti ile RO algoritması çalıştırılmıştır. Şekil 4.36’da tüm ürünlerin gözlem değerleri ve rastgele ormanlar sonucu tahmin değerleri verilmiştir.

Tüm ürünlerin yer aldığı veri seti için RO modeli sonucu elde edilen performans değerleri ise Çizelge 4.22’de verilmiştir.

Çizelge 4.22. Birleştirilmiş veri seti için renk detaysız RO performansı.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
Birleştirilmiş_Renksiz_RO	454,0569	0,9470	206167,7	203,8847




Şekil 4.36. Birleştirilmiş veri için renk detaysız gözlem ve RO tahmin değerleri.

Şekil 4.37'de de test için ayrılan verinin ilk 200 satırı için gözlem ve RO tahmin sonuçlarının grafiği verilmiştir.

RO yönteminin sağladığı imkanlardan biri olan önem sırasının belirlenmesi ile bağımsız değişkenlerin bağımlı değişken üzerindeki etkisini gözlemlenmektedir. Şekil 4.38'de tüm verilere uygulanan RO'nun sonucunda elde edilen önem sırası verilmiştir.




Tüm Veriler için RO Tahmini



Şekil 4.37. İlk 200 test verisi için renk detaysız gözlem ve RO tahmin değerleri.

Tüm Ürünler için Değişkenlerin Önem Değeri(RO) - Renk Detaysız




Şekil 4.38. Birleştirilmiş veri için renk detaysız RO sonucunda değişkenlerin önem sırası, a) MSE'ye olan etki sıralaması, b) düğüm saflığı sıralaması.

Şekil 4.38b’de görüldüğü üzere “*node purity*” yani düğüm saflığı sıralamasına göre *magazasayisi* değişkeni tüm veri setinin tahmin edildiği modelde en önemli değişken olarak dikkat çekmektedir. Sırasıyla *tutar*, *brutkar*, *psf* (*perakende satış fiyatı*), *urunad*, *gunsonureyonstok* ve diğer değişkenler önem sırasına göre listelenmiştir. Şekil 4.38a’da ise değişkenler MSE üzerinde en fazla etkiye sahip olandan daha az olana doğru sıralanmıştır. *tutar* değişkeninin MSE performansı üzerindeki etkisi %28,79 iken *magazasayisi* değişkeni %28,66 ile çok yakın bir değer almıştır. Ayrıca model sonucuna göre bağımlı değişkenin %93,54’ü bağımsız değişkenlerce açıklanabilmektedir.

#### 4.3.4.5. DBR Ürünü İçin RO Tahmin Uygulaması – Renk Detaysız

DBR ürününe ait renk çıkarılmış veri seti elde edilen modele uygulanmış ve tahmin sonuçları ile gözlem değerleri grafiği Şekil 4.39’da verilmiştir.




Şekil 4.39. DBR ürünü için renk detaysız gözlem ve RO tahmin değerleri.

DBR ürünü için kurulan ve çalıştırılan RO modeli sonucu elde edilen performans değerleri ise Çizelge 4.23'te verilmiştir.

Çizelge 4.23. DBR ürünü renk detaysız veri seti için RO performansı.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
DBR_Renksiz_ RO	218,5802	0,9901	47777,29	100,2925

Şekil 4.40'da ise DBR ürününün test için ayrılan verisinin ilk 200 satırı için gözlem ve RO tahmin değerleri arasındaki ilişki grafiği verilmiştir.




Şekil 4.40. DBR ürünü ilk 200 veri renk detaysız gözlem ve RO tahmin değeri.

Şekil 4.41b'de “*node purity*” yani düğüm saflığı sıralamasına göre *tutar* değişkeni tüm veri setinin tahmin edildiği modelde en önemli değişken olarak dikkat çekmektedir. Sırasıyla *brutkar*, *magazasayisi*, *usd* ve diğer değişkenler önem sırasına göre listelenmiştir. Şekil 4.41a'da ise değişkenler MSE üzerinde en fazla etkiye sahip olandan daha az olana doğru sıralanmıştır. *tutar* değişkeni üzerinde meydana gelecek

değişiklik MSE'yi %41,37 oranında etkilemektedir. Ayrıca model sonucuna göre bağımlı değişkenin %98,33'ü bağımsız değişkenlerce açıklanabilmektedir.

DBR - Değişkenlerin Önem Değeri(RO) - Renk Detaysız



Şekil 4.41. DBR için renk detaysız RO sonucunda elde edilen değişkenlerin önem sırası, a) MSE'ye olan etki sıralaması, b) düğüm saflığı sıralaması.

#### 4.3.4.6. Tüm Ürünler için RO Tahmin Sonuçları – Renk Detaysız

Önceki bölümlerde kurulan rastgele orman modeli tüm ürünler için renk detaysız veri üzerinden tek tek çalıştırılmıştır. Elde edilen performans değerleri Çizelge 4.24'de verilmiştir.


Çizelge 4.24. Tüm ürünler için renk detaysız RO performansları.

Model Adı	RMSE	R <sup>2</sup>	MSE	MAE
Birleştirilmiş_ Renksiz_RO	454,0569	0,9470	206167,70	203,8847
DBR_Renksiz_ RO	218,5802	0,9910	47777,29	100,2925

Çizelge 4.24. (devam ediyor).

<b>Model Adı</b>	<b>RMSE</b>	<b>R<sup>2</sup></b>	<b>MSE</b>	<b>MAE</b>
CNS_Renksiz_ RO	115,7988	0,9938	13409,36	48,1213
CTY_Renksiz_ RO	141,9428	0,9796	20147,75	76,0433
DSY_Renksiz_ RO	261,1037	0,9704	68175,16	77,8512
DMD_Renksiz_ RO	371,3464	0,9615	137898,10	199,4322
GTI_Renksiz_ RO	117,3658	0,9802	13774,73	56,4227
GTT_Renksiz_ RO	30,0207	0,9915	901,24	13,0137
MLN_Renksiz_ RO	235,6460	0,9797	55529,05	103,1403
RTK_Renksiz_ RO	323,4347	0,9879	104610,00	112,2564
SMT_Renksiz_ RO	242,1871	0,9821	58654,60	139,4249
TNT_Renksiz_ RO	169,3430	0,9906	28677,04	89,6723
YSM_Renksiz_ RO	213,5241	0,9764	45592,55	137,1404
ZCA_Renksiz_ RO	249,7371	0,9848	62368,60	116,3064

Çizelge 4.24'te yer alan sonuçlar karşılaştırma kolaylığı olması açısından normalize edilmiş ve Şekil 4.42'deki grafik çizilmiştir.



Şekil 4.42 Tüm tahminler için normalize edilmiş renk detaysız RO performans verileri.

#### 4.4. DENEYSEL SONUÇLAR

Bölüm 4.3'te yapay zeka yöntemlerinden yapay sinir ağları, destek vektör makineleri ve rastgele ormanlar yöntemleri veri setine uygulanmış ve sonuçlar elde edilmiştir.


Çizelge 4.28'de tüm yöntemler için ve tüm veri setleri için elde edilen RMSE değerleri verilmiştir. Çizelge 4.28'de yer alan toplam satırında ise her bir yöntemin en düşük RMSE değerini verdiği veri seti sayısı yer almaktadır. YSA yönteminin uygulandığı ve renk detayının çıkarıldığı veri setleri en düşük RMSE değerini veren yöntem olmuştur. Toplamda 14 adet veri setinden 8 adet veri setinde renk detaysız çalıştırılan YSA modeli başarılı sonuç vermiştir. DVM renk detaylı model 2 adet veri setinde en iyi performansı verirken, diğer tüm modeller birer veri setinde en iyi performansa sahip olmuşlardır.

Çizelge 4.28. Tüm veri setleri ve yöntemler için RMSE performansları.

Model Adı	YSA RMSE	YSA Renksiz RMSE	DVM RMSE	DVM Renksiz RMSE	RO RMSE	RO Renksiz RMSE
Birleştirilmiş Veri	112	<b>111</b>	141	166	458	454
DBR	<b>187</b>	247	215	226	244	219
CNS	165	202	150	163	119	<b>116</b>
CTY	127	98	<b>95</b>	102	144	142
DSY	203	<b>198</b>	246	278	264	261
DMD	224	<b>223</b>	239	250	374	371
GTI	78	<b>64</b>	73	85	120	117
GTT	52	34	75	78	<b>30</b>	30
MLN	143	<b>121</b>	185	201	228	236
RTK	203	<b>164</b>	221	229	323	323
SMT	223	209	190	<b>189</b>	237	242
TNT	151	<b>114</b>	187	192	167	169
YSM	200	244	<b>180</b>	185	193	214
ZCA	162	<b>144</b>	155	158	259	250
<i>Toplam</i>	<i>1</i>	<i>8</i>	<i>2</i>	<i>1</i>	<i>1</i>	<i>1</i>


Şekil 4.47’de çalışmada kullanılan yapay zeka yöntemleri için elde edilen RMSE değerleri sadece renk detayı içeren veri setleri için karşılaştırmalı olarak verilmiştir.

Yapay zeka yöntemleri arasında da performanslar veri setine göre değişiklik gösterse de Şekil 4.47’de de görüldüğü üzere rastgele ormanlar yönteminin yapay sinir ağları ve destek vektör makineleri yöntemlerine göre daha kötü sonuçlar verdiği gözlemlenmiştir.



řekil 4.47. Yapay zeka yontemleri iin renk detaylı RMSE sonuları.


řekil 4.48’da ise renk detaysız veri uzerinden alıřtırılan modeller sonucu elde edilen RMSE deęerleri verilmiřtir. Burada da renk detayanın dahil olduęu veri setlerinde elde edilen sonulara benzer sonular elde edilmiřtir ve yine en ktu performansı gsteren yontem olarak rastgele ormanlar yontemi ne ıkmıřtır.



řekil 4.48. Yapay zeka yontemleri iin renk detaysız RMSE sonuları.



Şekil 4.49’da Çizelge 4.28’de yer alan yapay sinir ağları, destek vektör makineleri ve rastgele ormanlar yöntemleri için renk detayının dahil olduğu veri seti ile renk detaysız veri seti sonuçlarının karşılaştırmalı grafikleri verilmiştir. Yapay sinir ağları ve rastgele ormanlar yönteminde renk detaysız verinin genel olarak daha iyi sonuç verdiği görülürken destek vektör makinelerinde ise renk detaylı veri daha iyi sonuçlar vermiştir.



Şekil 4.49. Yöntemlere göre karşılaştırmalı RMSE sonuçları.

Özet olarak her bir yöntemin renk detaylı ve detaysız versiyonlarının birbirine olan üstünlüğü Çizelge 4.29’da verilmiştir. YSA için toplam 14 veri setinden 11’i renk detaysız olarak çalıştırılan modelde daha iyi sonuç vererek daha düşük RMSE değerine sahip olmuştur. DVM için 13 adet veri seti renk detaylı olarak çalıştırıldığında renk detaysız veri setine göre daha başarılı olmuştur. RO ve klasik yöntemlerde ise renk detaylı veri seti ile renk detaysız veri setleri arasında çok fazla fark görülmemiştir.

Çizelge 4.29. Her bir yöntem için en düşük RMSE veren veri seti sayısı.

Yöntem	YSA	YSA Renksiz	DVM	DVM Renksiz	RO	RO Renksiz
Veri Seti Sayısı	3	11	13	1	6	8

Çizelge 4.30’da ise renk detaylı veriler için ve renk detaysız veriler için olmak üzere yapay zeka yöntemleri karşılaştırılmıştır. Renk bilgisinin dahil olduğu veri setlerinde YSA 7 veri setinde başarılı olmuşken DVM ise 5 veri setinde başarılı olmuştur. Renk detaysız verilerde ise YSA’nın daha iyi sonuçlar verdiği görülmüştür.

Çizelge 4.30. Yapay zeka yöntemlerinin veri setine göre karşılaştırmalı RMSE değerleri.

Model Adı	YSA RMSE	DVM RMSE	RO RMSE	YSA Renksiz RMSE	DVM Renksiz RMSE	RO Renksiz RMSE
<i>Birleştirilmiş Veri</i>	<i>112</i>	141	458	<i>111</i>	166	454
<i>DBR</i>	<i>187</i>	215	244	247	226	<i>219</i>
<i>CNS</i>	165	150	<i>119</i>	202	163	<i>116</i>
<i>CTY</i>	127	<i>95</i>	144	<i>98</i>	102	142
<i>DSY</i>	<i>203</i>	246	264	<i>198</i>	278	261
<i>DMD</i>	<i>224</i>	239	374	<i>223</i>	250	371
<i>GTI</i>	78	<i>73</i>	120	<i>64</i>	85	117
<i>GTT</i>	52	75	<i>30</i>	34	78	<i>30</i>
<i>MLN</i>	<i>143</i>	185	228	<i>121</i>	201	236
<i>RTK</i>	<i>203</i>	221	323	<i>164</i>	229	323
<i>SMT</i>	223	<i>190</i>	237	209	<i>189</i>	242
<i>TNT</i>	<i>151</i>	187	167	<i>114</i>	192	169
<i>YSM</i>	200	<i>180</i>	193	244	<i>185</i>	214
<i>ZCA</i>	162	<i>155</i>	259	<i>144</i>	158	250
<i>Toplam</i>	<i>7</i>	<i>5</i>	<i>2</i>	<i>9</i>	<i>2</i>	<i>3</i>


Bir diğ er değ erlendirme kriteri olan  $R^2$  için elde edilen tüm sonuçlar, kullanılan yöntemlere göre Çizelge 4.31’de verildiğ i gibidir.

Çizelge 4.31. Tüm veri setleri ve yöntemler için  $R^2$  performansları.

Model Adı	YSA $R^2$	YSA Renksiz $R^2$	DVM $R^2$	DVM Renksiz $R^2$	RO $R^2$	RO Renksiz $R^2$
Birleřtirilmiř Veri	0.9965	<b>0.9966</b>	0.9944	0.9922	0.9464	0.9470
DBR	<b>0.9934</b>	0.9888	0.9917	0.9911	0.9887	0.9910
CNS	0.9868	0.9800	0.9895	0.9882	0.9935	<b>0.9938</b>
CTY	0.9844	0.9903	<b>0.9911</b>	0.9897	0.9790	0.9796
DSY	0.9821	<b>0.9829</b>	0.9747	0.9681	0.9697	0.9704
DMD	<b>0.9845</b>	0.9842	0.9837	0.9822	0.9617	0.9615
GTI	0.9909	<b>0.9940</b>	0.9926	0.9902	0.9792	0.9802
GTT	0.9748	0.9902	0.9515	0.9476	<b>0.9918</b>	0.9915
MLN	0.9926	<b>0.9947</b>	0.9879	0.9856	0.9810	0.9797
RTK	0.9945	<b>0.9964</b>	0.9937	0.9933	0.9882	0.9879
SMT	0.9852	0.9868	0.9900	<b>0.9905</b>	0.9830	0.9821
TNT	0.9926	<b>0.9958</b>	0.9888	0.9881	0.9910	0.9906
YSM	0.9796	0.9683	<b>0.9823</b>	0.9813	0.9805	0.9764
ZCA	0.9932	<b>0.9946</b>	0.9941	0.9940	0.9837	0.9848
<i>Toplam</i>	<b>2</b>	<b>7</b>	<b>2</b>	<b>1</b>	<b>1</b>	<b>1</b>


Çizelge 4.31’de görüldüğü üzere toplam satırında yer alan verilere göre 7 veri setinde en yüksek performansı gösteren yöntem renk detaysız verilere uygulanan YSA yöntemi olarak belirlenmiştir.

Şekil 4.50’de çalışmada kullanılan yapay zeka yöntemleri için elde edilen  $R^2$  değ erleri sadece renk detayı içeren veri etleri için karşılařtırmalı olarak verilmiştir.



Şekil 4.50. Yapay zeka yöntemleri için renk detaylı  $R^2$  sonuçları.


RMSE performans kriterine benzer şekilde  $R^2$  için de performanslar veri setine göre değişiklik göstermekle birlikte, rastgele ormanlar yöntemi GTT veri setindeki diğer yöntemlere göre bariz yüksek performansı hariç, diğer veri setlerinde genel olarak YSA ve DVM yöntemlerinin gerisinde kalmıştır. Yine Şekil 4.50 incelendiğinde görülüyor ki YSA yöntemi diğer yöntemlere göre daha fazla veri setinde daha yüksek  $R^2$  değeri vermiştir.



Şekil 4.51. Yapay zeka yöntemleri için renk detaysız  $R^2$  sonuçları.

Şekil 4.51’de de renk detaysız veri üzerinden elde edilen  $R^2$  değerleri tüm yöntemler ve veri setleri için verilmiştir. Sonuçlar genel olarak renk detayının dahil olduğu veri setine benzer olarak elde edilmiştir. Yine GTT veri setinde rastgele ormanlar en iyi

performansı sağlarken, destek vektör makineleri hem renk detaylı hem de renk detaysız veri setlerinde en kötü performansı sağlamıştır.



Şekil 4.52. Yöntemlere göre karşılaştırmalı R<sup>2</sup> sonuçları.

Çizelge 4.31’de yer alan veriler karşılaştırmalı grafik olarak Şekil 4.52’de verilmiştir. Yapay sinir ağları yönteminde renk detaysız verinin daha iyi bir performans sağladığı görülürken, destek vektör makinelerinde ise renk detaylı verinin daha iyi sonuçlar verdiği gözlemlenmiştir. Rastgele ormanlar yöntemi ise veri setine göre farklılık göstermiş ve yarı yarıya dağılmıştır.

Her bir yöntem için renk detaylı ve detaysız olarak kurulan modellerin birbirlerine olan üstünlüğü Çizelge 4.32’de özet olarak verilmiştir. YSA için 14 veriden 10 tanesinin renk detaysız versiyonu, renk detaylı versiyona göre daha iyi sonuç vermiştir. DVM yönteminde bu sayı renk detaylı veri setleri lehine 13 olarak gerçekleşmiştir. RO yöntemi ise 14 adet veri setinin 7’sinde renk detaylı versiyonda daha iyi sonuçlar vermiş, geriye kalan 7’sinde ise renk detaysız versiyonda daha iyi

sonuçlar vermiştir. Klasik yöntemlerde ise üstel hareketli ortalama yönteminin bariz olarak daha iyi sonuçlar verdiği görülmektedir.

Çizelge 4.32. Her bir yöntem için en yüksek  $R^2$  veren veri seti sayısı.

Yöntem	YSA	YSA Renksiz	DVM	DVM Renksiz	RO	RO Renksiz
Veri Seti Sayısı	4	10	13	1	7	7

Çizelge 4.33. Yapay zeka yöntemlerinin veri setine göre karşılaştırmalı  $R^2$  performans değerleri.

Model Adı	YSA $R^2$	DVM $R^2$	RO $R^2$	YSA Renksiz $R^2$	DVM Renksiz $R^2$	RO Renksiz $R^2$
Tüm Ürünler	<b>0.9965</b>	0.9944	0.9464	<b>0.9966</b>	0.9922	0.9470
DBR	<b>0.9934</b>	0.9917	0.9887	0.9888	<b>0.9911</b>	0.9910
CNS	0.9868	0.9895	<b>0.9935</b>	0.9800	0.9882	<b>0.9938</b>
CTY	0.9844	<b>0.9911</b>	0.9790	<b>0.9903</b>	0.9897	0.9796
DSY	<b>0.9821</b>	0.9747	0.9697	<b>0.9829</b>	0.9681	0.9704
DMD	<b>0.9845</b>	0.9837	0.9617	<b>0.9842</b>	0.9822	0.9615
GTI	0.9909	<b>0.9926</b>	0.9792	<b>0.9940</b>	0.9902	0.9802
GTT	0.9748	0.9515	<b>0.9918</b>	0.9902	0.9476	<b>0.9915</b>
MLN	<b>0.9926</b>	0.9879	0.9810	<b>0.9947</b>	0.9856	0.9797
RTK	<b>0.9945</b>	0.9937	0.9882	<b>0.9964</b>	0.9933	0.9879
SMT	0.9852	<b>0.9900</b>	0.9830	0.9868	<b>0.9905</b>	0.9821
TNT	<b>0.9926</b>	0.9888	0.9910	<b>0.9958</b>	0.9881	0.9906
YSM	0.9796	<b>0.9823</b>	0.9805	0.9683	<b>0.9813</b>	0.9764
ZCA	0.9932	<b>0.9941</b>	0.9837	<b>0.9946</b>	0.9940	0.9848
<i>Toplam</i>	<b>7</b>	<b>5</b>	<b>2</b>	<b>9</b>	<b>3</b>	<b>2</b>

Çizelge 4.33'de yapay zeka yöntemleri renk detaylı ve renk detaysız olmak üzere kendi aralarında karşılaştırılmış ve en yüksek  $R^2$  değerini veren yöntemler toplanarak toplam satırına yazılmıştır. Burada açıkça görülüyor ki hem renk detayının dahil

olduđu veri setlerinde hem de renk detaysız veri setlerinde YSA yöntemi diđer yöntemlere göre daha iyi sonuçlar vermiştir. Renk detaylı verilerde DVM yöntemi 5 veri setinde daha iyi sonuç verirken RO yöntemi ise sadece 2 veri setinde daha iyi performans göstermiştir. Renk detaysız veri setlerinde ise DVM yöntemi sadece 3 veri setinde daha iyi sonuçlar verirken RO yöntemi yine 2 veri setinde daha iyi sonuçlar vermiştir.

Hem RMSE hem de  $R^2$  performans kriteri göz önüne alındığında yapay sinir ağlarının destek vektör makineleri ve rastgele ormanlar yöntemlerine göre daha iyi sonuçlar verdiği gözlemlenmiştir. Yapay zeka yöntemlerinin ise klasik yöntemlere göre son derece üstün olduđu görülmektedir.

## BÖLÜM 5

### SONUÇLAR VE TARTIŞMA

Her geçen gün artan önemi ile müşteri talebinin tahmini, firmaların tüm stratejilerini belirleyen temel etkenlerden biri olmuştur. Talepteki değişimler, sektör yapısı itibariyle çok hızlı gerçekleşmekte ve eğer müşteri talebi doğru tahmin edilemez ise satış kaybı meydana gelmektedir. Bununla birlikte müşterilerin diğer rakip firmaları tercih etme olasılığı da artmaktadır. Küresel bir pazarda yerli ve yabancı yatırımcıların bulunduğu bir rekabet ortamında, müşteri ihtiyaçlarının doğru tahmin edilmesi ve bu tahminlere göre aksiyon alınması hayatta kalmanın en temel gerekliliğidir.

Hazır giyim perakende sektöründe müşteri tahminlerini sağlıklı yapabilmek diğer sektörlerle göre biraz daha komplekstir ve literatür çalışmalarında da görüldüğü üzere geleneksel yöntemler talep tahminlerini tatmin edici sonuçlar ile açıklayamamaktadır. Ayrıca satışı etkileyen birçok faktör tahmin modeline dahil edilmelidir. Bu nedenle kurulan modellere bu değişkenler dahil edilerek tutarlı ve tatmin edici bir model kurulması amaçlanmıştır. Ayrıca veri setinin ürün bazında ve renk detayına incek şekilde analiz edilmiş olması ile birlikte tahmin tutarlılığını artırmak amacı desteklenmiştir.

Bu tez çalışması kapsamında perakende hazır giyim sektöründe faaliyet gösteren bir firma için yapay sinir ağları, destek vektör makineleri ve rastgele ormanlar modelleri kullanılarak talep tahmin çalışması yapılmıştır. Yapay zeka yöntemlerinin yanı sıra klasik yöntemlerden basit hareketli ortalama yöntemi ile üstel hareketli ortalama yöntemi de veri setlerine uygulanarak tahmin çalışması yapılmıştır.

Çalışmada her bir ürün için tek tek tahmin yapılırken aynı zamanda tüm ürünler tek bir veri seti şeklinde modellere uygulanarak modeller çalıştırılmıştır. Böylece



yöntemlerin görece daha büyük veride verdiği sonuçlar ile ürün bazında yapılan tahmin sonuçlarını karşılaştırma imkanı doğmuştur. Ayrıca veri setlerine dahil edilen ulusal ekonomik göstergeler, hava durumu, özel günler, satış fiyatı gibi değişkenler ile tahmin doğruluğu arttırılmıştır.

Elde edilen sonuçlar incelendiğinde yapay sinir ağlarının ürünün renginin dahil olmadığı veri setlerinde daha iyi sonuçlar verdiği görülürken, destek vektör makinelerinin ise renk detayının dahil olduğu veri setlerinde daha iyi sonuçlar verdiği görülmüştür. Rastgele ormanlar yöntemi ise diğer iki yöntemden ayrılarak veri setlerinde benzer sonuçlar göstermişlerdir. Tüm veri setlerinden elde edilen sonuçlara göre ise yapay sinir ağlarının diğer yöntemlere göre daha iyi performans gösterdiği ve tüm yapay zeka sistemlerinin performanslarının başarılı olduğu gözlemlenmiştir. Faktör değişken olan renk detayının eklenmesiyle birlikte ANN performansı, birleştirilmiş veri seti için renk detaylı ve renk detaysız veri setleri arasında %1.13 değişmiştir. DVM ise renk detaylı veri setinde renk detaysız veri setine göre %15.15 daha iyi bir performans göstermiştir. Toplam 14 veri setinden 8'inde YSA renk detaysız modelleri en iyi sonucu vermiştir. Modellerin kendi içinde karşılaştırmasında ise YSA 14 veri setinin 13'ünde renk detaysız veri setinde başarılı olmuşken, DVM ise 13 veri setinde renk detaylı modellerde daha başarılı olmuştur. RO yönteminde ise renk detaylı ve renk detaysız veri seti arasında kayda değer bir fark oluşmamıştır. Sadece renk detaylı veriler göz önüne alındığında YSA 7 modelde, DVM 5 modelde ve RO ise 2 modelde diğerlerine göre daha iyi sonuçlar verirken, renk detaysız veri setlerinde YSA 9 modelde, DVM 2 modelde ve RO 3 modelde diğer modellere göre daha iyi sonuçlar vermiştir. Bununla birlikte talep tahminini ürünün renk detayı ile birlikte, doğru bir şekilde yapmanın stok maliyetinin ve satış kaybının iyileştirilmesi üzerinde önemli bir etkisi vardır.

Verilerin günlük olarak ve çok büyük rakamlarda elde edildiği perakende sektöründe yapılan bu çalışma, gerçek zamanlı verilere ve daha büyük veri setlerine uygulanması durumunda oldukça yararlı sonuçlar verebilir. Ürün özelinde renk detayı gibi, ürünün beden bilgisinin veri setine dahil edilerek veri setinin detaylandırılmasının da tahmin performansı üzerinde etkili olabileceği düşünülmektedir. Ayrıca daha gelişmiş yapay zeka teknikleri ya da yapay sinir ağları

ile hibritlenen diđer yöntemleri kullanarak tahmin performansları izlenebilir ve tatmin edici sonuçlar elde edilebilir. Günümüzde giderek yaygınlaşan derin öğrenme yöntemleri de talep tahmini çalışmalarında kullanılarak çok daha doğru sonuçlar elde edilebilir.

## KAYNAKLAR

1. Şenel, A., "Yönlendirici bir faktör olarak moda olgusunun hazır giyim sektörü üzerindeki etkisinin incelenmesi ve baskı desenlerini belirleyici bir faktör olarak trendler", Yüksek Lisans Tezi, *İstanbul Arel Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, (2019).
2. Özcan, M., "Dünyada ve Türkiye’de hazır giyim sektörünün uluslararası ticaretinin incelenmesi ve değerlendirilmesi", Yüksek Lisans Tezi, *İstanbul Ticaret Üniversitesi Dış Ticaret Enstitüsü*, İstanbul, (2018).
3. Çebi, E., "Hazır giyim sektöründe markalaşmayı etkileyen faktörler: istanbul’daki hazır giyim sektöründe marka oluşturmada karşılaşılan engeller üzerine bir uygulama", Yüksek Lisans Tezi, *Beykent Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, (2012).
4. Eraslan, İ. H., Bakan, İ., and Helvacıoğlu Kuyucu, A. D., "Türk tekstil ve hazır giyim sektörünün uluslararası rekabetçilik düzeyinin analizi", *İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi*, 7 (13): 265–300 (2008).
5. Uzunoglu, H., "Türk hazır giyim ve tekstil sektörünün 2008 yılı rekabet durumu(II)", *İzmir Ticaret Odası AR&GE Bülten*, İzmir, (2008).
6. Bashimov, G., "Türk tekstil ve hazır giyim sektörünün uluslararası rekabet gücü: ASEAN-5 ülkeleri ile karşılaştırmalı analiz", *Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 4 (2): 1–15 (2017).
7. Bostan, A., Ateş, İ., and Ürüt, S., "Türkiye tekstil ve hazır giyim sektörünün rekabet gücü: Avrupa Birliği ülkeleri ile bir karşılaştırma", *Yönetim Ve Ekonomi Araştırmaları Dergisi*, 8 (13): 43–58 (2010).
8. Uyanık, Ş. and Çelikel, D. C., "Türk tekstil endüstrisi genel durumu", *Teknik Bilimler Dergisi*, 9 (1): 32–41 (2019).
9. Güllüoğlu, E. N. and Taçgın, E., "Türkiye tekstil sektöründe istihdam ve iş kazalarının analizi", *Tekstil Ve Mühendis*, 25 (112): 344–354 (2018).
10. Odabaş, S., "Tekstil Sektöründe İhracat Yapan Firmada Talep Tahmini Uygulaması", Yüksek Lisans Tezi, *Karabük Üniversitesi Fen Bilimleri Enstitüsü*, Karabük, (2019).
11. Zhou, S. L., McMahon, T. A., Walton, A., and Lewis, J., "Forecasting daily urban water demand: a case study of Melbourne", *Journal Of Hydrology*, 236 (3–4): 153–164 (2000).
12. Zhai, Y., Wang, J., Teng, Y., and Zuo, R., "Water demand forecasting of Beijing using the Time Series Forecasting Method", *Journal Of Geographical*

*Sciences*, 22 (5): 919–932 (2012).

13. Whiting, D. G., Tolley, H. D., and Fellingham, G. W., "An empirical Bayes procedure for adaptive forecasting of shrimp yield", *Aquaculture*, 182 (3–4): 215–228 (2000).
14. Rajopadhye, M., Ben Ghalia, M., Wang, P. P., Baker, T., and Eister, C. V., "Forecasting uncertain hotel room demand", *Information Sciences*, 132 (1–4): 1–11 (2001).
15. Greenidge, K., "Forecasting tourism demand: An STM approach", *Annals Of Tourism Research*, 28 (1): 98–112 (2001).
16. Lim, C. and McAleer, M., "Time series forecasts of international travel demand for Australia", *Tourism Management*, 23 (4): 389–396 (2002).
17. Ediger, V. Ş. and Tatlıdil, H., "Forecasting the primary energy demand in Turkey and analysis of cyclic patterns", *Energy Conversion And Management*, 43 (4): 473–487 (2002).
18. Altay, N., Rudisill, F., and Litteral, L. A., "Adapting Wright's modification of Holt's method to forecasting intermittent demand", *International Journal Of Production Economics*, 111 (2): 389–408 (2008).
19. Thomas Ng, S., Skitmore, M., and Wong, K. F., "Using genetic algorithms and linear regression analysis for private housing demand forecast", *Building And Environment*, 43 (6): 1171–1184 (2008).
20. Pappas, S. S., Ekonomou, L., Karampelas, P., Karamousantas, D. C., Katsikas, S. K., Chatzarakis, G. E., and Skafidas, P. D., "Electricity demand load forecasting of the Hellenic power system using an ARMA model", *Electric Power Systems Research*, 80 (3): 256–264 (2010).
21. Özer, Ö. and Erkilet, M., "Talep analizi ve talep öngörüsü: bir özel hastanede uygulama", *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 14 (3): 127–142 (2012).
22. Bergman, J. J., Noble, J. S., McGarvey, R. G., and Bradley, R. L., "A Bayesian approach to demand forecasting for new equipment programs", *Robotics And Computer-Integrated Manufacturing*, 47: 17–21 (2017).
23. Bacci, L. A., Mello, L. G., Incerti, T., Paulo de Paiva, A., and Balestrassi, P. P., "Optimization of combined time series methods to forecast the demand for coffee in Brazil: A new approach using Normal Boundary Intersection coupled with mixture designs of experiments and rotated factor scores", *International Journal Of Production Economics*, 212: 186–211 (2019).
24. Law, R., "Back-propagation learning in improving the accuracy of neural network-based tourism demand forecasting", *Tourism Management*, 21 (4): 331–340 (2000).

25. Darbellay, G. A. and Slama, M., "Forecasting the short-term demand for electricity: Do neural networks stand a better chance?", *International Journal Of Forecasting*, 16 (1): 71–83 (2000).
26. Akyurt, İ. Z., "Artificial neural network modeling of demand forecast: Case of domestic car", *Ekonometri Ve İstatistik E-Dergisi*, (23): 147–157 (2016).
27. KARAHAN, M., "Forecasting amount of export demand with Artificial Neural Networks method: A comparative analysis of ARIMA and ANN", *Ege Akademik Bakış Dergisi*, 15 (2): 165–172 (2015).
28. Günay, M. E., "Forecasting annual gross electricity demand by artificial neural networks using predicted values of socio-economic indicators and climatic conditions: Case of Turkey", *Energy Policy*, 90: 92–101 (2016).
29. Akkol, S., Akıllı, A., and Cemal, İ., "Kıl keçilerinin canlı ağırlık tahmininde Yapay Sinir Ağları ve Çoklu Doğrusal Regresyon yöntemlerinin karşılaştırılması", *Yüzüncü Yıl Üniversitesi Tarım Bilimleri Dergisi*, 27 (1): 21–29 (2017).
30. Tanizaki, T., Hoshino, T., Shimmura, T., and Takenaka, T., "Demand forecasting in restaurants using machine learning and statistical analysis", *Procedia CIRP*, 79: 679–683 (2019).
31. Tüzüntürk, S., Eteman, F. S., and Sezen, H. K., "Yapay sinir ağı yöntemi ile damacana su satış miktarlarının tahmini", *Akademik Bakış Uluslararası Hakemli Sosyal Bilimler Dergisi*, (56): 129–145 (2016).
32. Ecemiş, O. and Irmak, S., "Paslanmaz çelik sektörü satış tahmininde veri madenciliği yöntemlerinin karşılaştırılması", *Sosyal Bilimler Dergisi*, 8 (15): 148–169 (2018).
33. Sönmez, O. and Zengin, K., "Yiyecek ve içecek işletmelerinde talep tahmini: Yapay Sinir Ağları ve Regresyon yöntemleriyle bir karşılaştırma", *European Journal Of Science And Technology*, 302–308 (2019).
34. Kuo, R. J. and Xue, K. C., "Fuzzy neural networks with application to sales forecasting", *Fuzzy Sets And Systems*, 108 (2): 123–143 (1999).
35. Green, M. and Harrison, P. J., "Fashion forecasting for a mail order company using a Bayesian approach", *Operational Research Quarterly*, 24 (2): 193–205 (1973).
36. Frank, C., Garg, A., Sztandera, L., and Raheja, A., "Forecasting women's apparel sales using mathematical modeling", *International Journal Of Clothing Science And Technology*, 15 (2): 107–125 (2003).
37. Thomassey, S. and Fiordaliso, A., "A hybrid sales forecasting system based on clustering and decision trees", *Decision Support Systems*, 42 (1): 408–421 (2006).

38. Sabir, E. C. and Batuk, E., "Demand forecasting withof using time series models in textile dyeing-finishing mills", *Tekstil Ve Konfeksiyon*, 23 (2): 143–151 (2013).
39. Kalaoğlu, Ö. İ., Akyuz, E. S., Ecemiş, S., Eryürük, S. H., Sümen, H., and Kalaoğlu, F., "Retail demand forecasting in clothing industry", *Tekstil Ve Konfeksiyon*, 25 (2): 172–178 (2015).
40. Li, C. and Lim, A., "A greedy aggregation–decomposition method for intermittent demand forecasting in fashion retailing", *European Journal Of Operational Research*, 269 (3): 860–869 (2018).
41. Ren, S., Chan, H.-L., and Siqin, T., "Demand forecasting in retail operations for fashionable products: methods, practices, and real case study", *Annals Of Operations Research*, (2019).
42. Solano Meza, J. K., Orjuela Yepes, D., Rodrigo-Illarri, J., and Cassiraga, E., "Predictive analysis of urban waste generation for the city of Bogotá, Colombia, through the implementation of decision trees-based machine learning, support vector machines and artificial neural networks", *Heliyon*, 5 (11): (2019).
43. Zheng, G., Zhang, W., Zhang, W., Zhou, H., and Yang, P., "Neural network and support vector machine models for the prediction of the liquefaction-induced uplift displacement of tunnels", *Underground Space*, (2020).
44. Shao, M., Wang, X., Bu, Z., Chen, X., and Wang, Y., "Prediction of energy consumption in hotel buildings via support vector machines", *Sustainable Cities And Society*, 57: (2020).
45. Baba, B. and Sevil, G., "Predicting IPO initial returns using random forest", *Borsa Istanbul Review*, 20 (1): 13–23 (2020).
46. Liu, N., Ren, S., Choi, T. M., Hui, C. L., and Ng, S. F., "Sales forecasting for fashion retailing service industry: A review", *Mathematical Problems In Engineering*, 2013: (2013).
47. Mostard, J., Teunter, R., and de Koster, R., "Forecasting demand for single-period products: A case study in the apparel industry", *European Journal Of Operational Research*, 211 (1): 139–147 (2011).
48. Ren, S., Choi, T. M., and Liu, N., "Fashion sales forecasting with a panel data-based particle-filter model", *IEEE Transactions On Systems, Man, And Cybernetics: Systems*, 45 (3): 411–421 (2015).
49. Syntetos, A. A. and Boylan, J. E., "The accuracy of intermittent demand estimates", *International Journal Of Forecasting*, 21 (2): 303–314 (2005).
50. Demiriz, A., "Demand Forecasting Based on Pairwise Item Associations", *Procedia Computer Science*, 36: 261–268 (2014).

51. Ren, S., Chan, H. L., and Ram, P., "A comparative study on fashion demand forecasting models with multiple sources of uncertainty", *Annals Of Operations Research*, 257 (1–2): 335–355 (2017).
52. Sun, Z.-L., Choi, T.-M., Au, K.-F., and Yu, Y., "Sales forecasting using extreme learning machine with applications in fashion retailing", *Decision Support Systems*, 46 (1): 411–419 (2008).
53. Xia, M. and Wong, W. K., "A seasonal discrete grey forecasting model for fashion retailing", *Knowledge-Based Systems*, 57: 119–126 (2014).
54. Aksoy, A., Ozturk, N., and Sucky, E., "A decision support system for demand forecasting in the clothing industry", *International Journal Of Clothing Science And Technology*, 24 (4): 221–236 (2012).
55. Au, K.-F., Choi, T.-M., and Yu, Y., "Fashion retail forecasting by evolutionary neural networks", *International Journal Of Production Economics*, 114 (2): 615–630 (2008).
56. Demiriz, A., Ertek, G., Atan, T., and Kula, U., "Re-mining item associations: Methodology and a case study in apparel retailing", *Decision Support Systems*, 52 (1): 284–293 (2011).
57. Wong, W. K. and Guo, Z. X., "A hybrid intelligent model for medium-term sales forecasting in fashion retail supply chains using extreme learning machine and harmony search algorithm", *International Journal Of Production Economics*, 128 (2): 614–624 (2010).
58. Yıldırım, A., "Talep tahmin yöntemlerinin karşılaştırmalı analizi: Gıda sektöründe bir uygulama", Yüksek Lisans Tezi, *İstanbul Kültür Üniversitesi Lisansüstü Eğitim Enstitüsü*, İstanbul, (2019).
59. Aydoğdu, G., "Geleneksel ve melez tahmin yöntemleri kullanılarak Türkiye elektrik talep tahmini", Yüksek Lisans Tezi, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara, (2019).
60. Sarı, M., "Yapay sinir ağları ve bir otomotiv firmasında satış talep tahmini uygulaması", Yüksek Lisans Tezi, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü*, Sakarya, (2016).
61. 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*, İstanbul, (2009).
62. Bilişik, M. T., "Destek Vektör Makinesi, Çoklu Regresyon ve Doğrusal Olmayan Programlama ile Perakendecilik Sektöründe Gelir Yönetimi İçin Dinamik Fiyatlandırma", *XI. Üretim Araştırmaları Sempozyumu*, 785–799 (2011).
63. Güner, N. and ÇOMAK, E., "Mühendislik Öğrencilerinin Matematik I Derslerindeki Başarısının Destek Vektör Makineleri Kullanılarak Tahmin

- Edilmesi", *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 17 (2): 87–96 (2011).
64. Yakut, E., Elmas, B., and Yavuz, S., "Yapay Sinir Ağları Ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini", *Süleyman Demirel Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, 19 (1): 139–157 (2014).
  65. Tolun, S., "Destek Vektör Makineleri: Banka Başarısızlığının Tahmini Üzerine Bir Uygulama", Doktora Tezi, *İstanbul Üniversitesi Sosyal Bilimler Enstitüsü*, İstanbul, (2008).
  66. Meral, G., "Türkiye'deki Enerji Santrallerinde Doğal Gaz Tüketiminin Destek Vektör Regresyon İle Tahmini", Yüksek Lisans Tezi, *Afyon Kocatepe Üniversitesi Fen Bilimleri Enstitüsü*, Afyon, (2019).
  67. Hazim, L. R., "Four Classification Methods Naive Bayesian, Support Vector Machine, K-Nearest Neighbors and Random Forest Are Tested For Credit Card Fraud Detection", M. Sc. Thesis, *Altınbas University Graduate School Of Sciences Engineering*, İstanbul, (2018).
  68. Einlou, H., "SARIMA Ve Destek Vektör Regresyon Yöntemleri İle Talep Tahmini", Yüksek Lisans Tezi, *Gazi Üniversitesi Fen Bilimleri Enstitüsü*, Ankara, (2019).
  69. Bayraktar, B., "Rastgele Ormanlar Ve Aşırı Öğrenme Makineleri Teknikleri İle Oltalama Saldırılarının Tespiti", Yüksek Lisans Tezi, *İstanbul Üniversitesi Lisansüstü Eğitim Enstitüsü*, İstanbul, (2019).
  70. Sabancı, D., "Rastgele Orman Yaklaşımı Kullanılarak Çok Değişkenli Uyumlu Regresyon Şeritlerinde Model Seçimi", Doktora Tezi, *Ondokuz Mayıs Üniversitesi Fen Bilimleri Enstitüsü*, Samsun, (2019).
  71. Güre, Ö. B., "Öğrencilerin Matematik Başarılarını Etkileyen Faktörlerin Rastgele Orman, Çok Katmanlı Algılayıcı ve Radyal Tabanlı Fonksiyon Yapay Sinir Ağları Yöntemleri İle Tahminleme Yeteneği Açısından Karşılaştırılması: Türkiye Örneği", Doktora Tezi, *Van Yüzüncü Yıl Üniversitesi Fen Bilimleri Enstitüsü*, Van, (2019).
  72. Atasever, Ü. H., "Uydu Görüntülerinin Sınıflandırılmasında Hızlandırma (boosting), Destek Vektör Makineleri, Rastgele Orman (Random Forest) Ve Regresyon Ağaçları Yöntemlerinin Kullanılması", Yüksek Lisans Tezi, *Erciyes Üniversitesi Fen Bilimleri Enstitüsü*, Kayseri, (2011).
  73. Kuhn, M., "Building Predictive Models in R Using the caret Package", *Journal Of Statistical Software*, 28 (5): (2008).
  74. Internet: Project, R., "R Studio", <https://www.r-project.org> (2019).
  75. Ecemiş, O., "Veri madenciliği yöntemleri ile paslanmaz çelik sektöründe satış tahmini", Doktora Tezi, *Akdeniz Üniversitesi Sosyal Bilimler Enstitüsü*,



Antalya, (2016).

76. Scornet, E., "Tuning Parameters In Random Forests", *Esaim: Proceedings And Surveys*, 60: 144–162 (2018).

## **ÖZGEÇMİŞ**

İlker GÜVEN 1992’de İstanbul Bakırköy’de doğdu. İlk, orta ve lise öğrenimini aynı şehirde tamamladı. 2010 yılında Avcılar Mesleki Teknik ve Anadolu Lisesi Elektrik Elektronik Teknolojisi Alanı’ndan mezun oldu. Aynı yıl başladığı İstanbul Üniversitesi Teknik Bilimler Meslek Yüksekokulu Kontrol ve Otomasyon Teknolojisi bölümünden 2012 yılında mezun oldu. 2012 yılında başladığı Karabük Üniversitesi Endüstri Mühendisliği bölümünü 2016 yılında bitirdikten sonra 2017 yılında aynı üniversitede Fen Bilimleri Enstitüsü Endüstri Mühendisliği anabilim dalında başladığı yüksek lisans eğitimine halen devam etmektedir. 2016-2018 yılları arasında Buka Sofa mobilya şirketinde Planlama Mühendisi olarak çalıştı. 2018 yılında başladığı LC Waikiki Mağazacılık Hizmetleri Ticaret A.Ş.’da Overseas Sourcing departmanında Overseas Sourcing Uzmanı olarak çalışmaya devam etmektedir.

### **ADRES BİLGİLERİ**

Adres : Saadetdere Mah. 7. Sokak No:93/3 Esenyurt İstanbul

Tel : (534) 451 2749

E-posta : ilkerguv@gmail.com