



**TARIMSAL VE SOSYO-EKONOMİK
GÖSTERGELERLE TARIM KREDİLERİ TAHMİNİ:
MAKİNE ÖĞRENMESİ VE İSTATİSTİKSEL
MODELLERİN KARŞILAŞTIRILMASI**

Abdurrahim KÖPRÜCÜ

Yüksek Lisans Tezi

Organik Tarım İşletmeciliği

Ana Bilim Dalı

Doç. Dr. Didem GÜLERYÜZ ÖZDEN

2025

(Her Hakkı Saklıdır)

T.C.
BAYBURT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ
ORGANİK TARIM İŞLETMECİLİĞİ ANA BİLİM DALI
ORGANİK TARIM İŞLETMECİLİĞİ TEZLİ YÜKSEK LİSANS PROGRAMI

TARIMSAL VE SOSYO-EKONOMİK GÖSTERGELERLE TARIM KREDİLERİ
TAHMİNİ: MAKİNE ÖĞRENMESİ VE İSTATİSTİKSEL MODELLERİN
KARŞILAŞTIRILMASI

YÜKSEK LİSANS TEZİ

Abdurrahim KÖPRÜCÜ

Danışman: Doç. Dr. Didem GÜLERYÜZ ÖZDEN

BAYBURT- 2025

KABUL VE ONAY

Doç. Dr. Didem GÜLERYÜZ ÖZDEN danışmanlığında, Abdurrahim KÖPRÜCÜ tarafından hazırlanan “Tarımsal ve Sosyo-Ekonomik Göstergelerle Tarım Kredileri Tahmini: Makine Öğrenmesi ve İstatistiksel Modellerin Karşılaştırılması” başlıklı bu çalışma, 15.01.2025 tarihinde yapılan savunma sınavı sonucunda oy birliği ile başarılı bulunarak jürimiz tarafından Yüksek Lisans Tezi olarak kabul edilmiştir.

Başkan : Doç. Dr. Didem GÜLERYÜZ ÖZDEN

Üye : Doç. Dr. Ömer Faruk EFE

Üye : Dr. Öğr. Üyesi Çağatay TEKE

Bu tezin kabulü Lisansüstü Eğitim Enstitüsü Yönetim Kurulu’nun/...../20... tarih ve 20...../.....-..... sayılı kararıyla onaylanmıştır.

Doç. Dr. Bünyamin ALİM
Enstitü Müdürü

BEYANNAME

Bayburt Üniversitesi Lisansüstü Eğitim Enstitüsü tez yazım kılavuzuna göre Doç. Dr. Didem GÜLERYÜZ ÖZDEN danışmanlığında hazırlamış olduğum “Tarımsal ve Sosyo-Ekonomik Göstergelerle Tarım Kredileri Tahmini: Makine Öğrenmesi ve İstatistiksel Modellerin Karşılaştırılması” başlıklı program seçin tezimin bilimsel etik değerlere ve kurallara uygun, özgün bir çalışma olduğunu, aksinin tespit edilmesi halinde her türlü yasal yaptırımını kabul edeceğimi beyan ederim.

25.12.2024

Abdurrahim KÖPRÜCÜ



ÖN SÖZ

Yüksek lisans eğitimim süresince her zaman bana vakit ayıran, karşılaştığım problemleri çözmemde yardımcı olan ve her alanda tecrübesinden faydalandığım, tez çalışmamın sonuna gelmemi sağlayan değerli danışman hocam sayın Doç. Dr. Didem GÜLERYÜZ ÖZDEN'e sonsuz teşekkürlerimi sunarım. Bu süreçte kıymetli jüri hocalarım sayın Doç. Dr. Ömer Faruk EFE ve sayın Dr. Öğr. Üyesi Çağatay TEKE hocalarıma desteklerinden dolayı teşekkürlerimi sunarım.

Bu zorlu süreçte yanımda olan, desteklerini esirgemeyen sevgili eşim Rukiye KÖPRÜCÜ'ye anlayışı ve destekleri için çok teşekkür ederim. Bu günlere gelmemi sağlayan hayatımın her döneminde desteklerini esirgemedi, tüm maddi ve manevi zorluklara rağmen yanımda olan annem Sema KÖPRÜCÜ ve babam Faysal KÖPRÜCÜ'ye, kardeşlerim Mustafa KÖPRÜCÜ ve Sevim AYGÜNOĞLU başta olmak üzere tüm aileme teşekkür ederim.

Yine bu süreçte Bayburt üniversitesi rektörü sayın Mutlu TÜRKMEN hocama, Bayburt Üniversitesi genel sekreteri sayın Nazmi KARABULUT hocama desteklerinden dolayı teşekkürlerimi sunarım. Sultan GÜÇTEKİN hanıma, lisansüstü eğitim enstitüsü personellerine, sayın Erdem KABAN'a ve sayın Napoleon RUGERINYANGE'ye desteklerinden dolayı teşekkür ediyorum.

Abdurrahim KÖPRÜCÜ

ÖZET

YÜKSEK LİSANS TEZİ

TARIMSAL VE SOSYO-EKONOMİK GÖSTERGELERLE TARIM KREDİLERİ TAHMINİ: MAKİNE ÖĞRENMESİ VE İSTATİSTİKSEL MODELLERİN KARŞILAŞTIRILMASI

Abdurrahim KÖPRÜCÜ

Bayburt Üniversitesi

Lisansüstü Eğitim Enstitüsü

Organik Tarım İşletmeciliği Ana Bilim Dalı

Tez Danışmanı: Doç. Dr. Didem GÜLERYÜZ ÖZDEN

Bayburt-2025, Sayfa: 114

Tarımsal üretim, ekonomik büyüme ve kırsal kalkınma açısından stratejik öneme sahiptir. Bu çalışmada, Türkiye'de 2000-2022 yıllarını kapsayan verilerle tarımsal kredilerin tahmininde makine öğrenmesi ve istatistiksel modellerin performansları karşılaştırılmıştır. Analizde tarım arazileri, sulama oranları, tatlı su çekimi, kentsel nüfus oranı ve tarımsal katma değer gibi değişkenler bağımsız değişken olarak kullanılmıştır. Analiz sürecinde Gauss Süreç Regresyonu, Destek Vektör Regresyonu, Topluluk Öğrenmeleri, Yapay Sinir Ağları, Karar Ağaçları ve Çoklu Doğrusal Regresyon yöntemleri değerlendirilmiştir. Elde edilen bulgular, GPR modelinin test aşamasında en yüksek tahmin doğruluğunu sağladığını ve doğrusal olmayan karmaşık ilişkileri modelleme kapasitesinin üstün olduğunu göstermiştir. GPR modelini Topluluk Öğrenmeleri yöntemi takip ederken, SVR modeli de dikkate değer bir performans sergilemiştir. Bununla birlikte, YSA ve Karar Ağaçları modellerinin genelleme kapasitelerinin sınırlı olduğu gözlemlenmiştir. Çalışmada, çoklu doğrusal bağımlılık probleminin çözümü için Ana Bileşen Analizi (PCA) uygulanmış ve temel bileşenler yardımıyla veri boyutu düşürülerek model performanslarının artırıldığı tespit edilmiştir. Sonuç olarak, bu tezde makine öğrenmesi yöntemlerinin tarımsal kredilerin tahmininde istatistiksel yöntemlere göre daha yüksek doğruluk sunduğu tespit edilmiştir. Elde edilen bulgular, makine öğrenmesi modellerinin tarımsal kredi politikalarının geliştirilmesi ve kırsal kalkınmanın desteklenmesinde etkili bir araç olabileceğini göstermektedir. Gelecekte, daha geniş veri setleri ve hibrit yaklaşımların kullanımı önerilmektedir.

Anahtar Kelimeler: Tarım kredileri, makine öğrenmesi, istatistiksel yöntemler.

ABSTRACT

M. SC. THESIS

AGRICULTURAL CREDIT ESTIMATION WITH AGRICULTURAL AND SOCIO-ECONOMIC INDICATORS: A COMPARISON OF MACHINE LEARNING AND STATISCAL MODELS

Abdurrahim KÖPRÜCÜ

Bayburt University

Institute of Graduate Studies

Department of Organic Agriculture Management

Thesis Advisor: Assoc. Prof. Dr. Didem GÜLERYÜZ ÖZDEN

Bayburt-2025, Pages:114

Agricultural production is strategically important in terms of economic growth and rural development. In this study, the performances of machine learning and statistical models were compared to estimate agricultural credits with data covering the years 2000-2022 in Turkey. Variables such as agricultural lands, irrigation rates, freshwater withdrawal, urban population rate and agricultural added value were used as independent variables in the analysis. Gaussian Process Regression, Support Vector Regression, Ensemble Learning, Artificial Neural Networks, Decision Trees and Multiple Linear Regression methods were evaluated in the analysis process. The findings showed that the GPR model provided the highest estimation accuracy in the test phase, and its capacity to model nonlinear complex relationships was superior. While the GPR model was followed by the Ensemble Learning method, the SVR model also exhibited a remarkable performance. However, it was observed that the generalization capacities of ANN and Decision Tree models were limited. In the study, Principal Component Analysis (PCA) was applied to solve the multicollinearity problem. It was determined that the model performances were increased by reducing the data size with the help of principal components. As a result, this thesis has defined machine learning methods as providing higher accuracy in estimating agricultural credits than statistical methods. The findings show that machine learning models can be an effective tool in developing agricultural credit policies and supporting rural development. Using more extensive data sets and hybrid approaches is recommended in the future.

Keywords: Agricultural Credits, machine learning, statistical methods.

İÇİNDEKİLER

KABUL VE ONAY.....	II
BEYANNAME	III
ÖN SÖZ	IV
ÖZET	V
ABSTRACT	VI
İÇİNDEKİLER.....	VII
TABLOLAR.....	X
ŞEKİLLER.....	XI
KISALTMALAR.....	XII
SİMGELER.....	XIII
GİRİŞ.....	1
Araştırmanın Konusu ve Problemi	2
Araştırmanın Amacı	3
Araştırmanın Önemi ve Gerekçesi	6
Araştırmanın Sınırlılıkları	7
Varsayımlar	8
BİRİNCİ BÖLÜM.....	10
1. KURAMSAL ÇERÇEVE	10
1.1. TARIM SEKTÖRÜNÜN GELİŞİMİ.....	10
1.1.1. Tarım Sektörünün Tarihsel Gelişimi	10
1.1.2. Türkiye’de Tarım Sektörünün Gelişimi	11
1.2. TARIM SEKTÖRÜ VE ÖNEMİ	14
1.2.1. Tarım Sektörünün Ekonomiye Katkısı	15
1.3. TARIM SEKTÖRÜNÜN TÜRKİYE EKONOMİSİNDEKİ YERİ VE ÖNEMİ	18
1.3.1. Tarımın GSYH’deki Yeri ve Önemi	21
1.3.2. Tarım Sektörünün Dış Ticaretteki Payı ve Önemi	23
1.3.3. Tarım Sektörünün Sanayiye Katkısı.....	24
1.4. TÜRKİYE’DE TARIMSAL POLİTİKALAR	25
1.4.1. Tarımsal Destekleme Ödemelerinin Bütçe İçerisindeki Payı.....	28
1.5. GENEL ANLAMDA KREDİ KAVRAMI	29
1.5.1. Kredinin Unsurları.....	30
1.5.2. Kredinin İşlevleri	31
1.5.3. Veriliş Amacı Açısından Krediler	32
1.6. TARIM KREDİLERİ	32
1.6.1. Tarımda Finansman Kaynakları	34
1.6.2. Tarımsal Kredilerin Sınıflandırılması.....	35
1.6.3. Türkiye’de Tarımsal Kredi Sağlayan Kuruluşlar	36
1.6.3.1. Bankalar ve tarım kredi kooperatifleri	36
1.7. LİTERATÜR TARAMASI	39
İKİNCİ BÖLÜM	42
2. YÖNTEM	42
2.1. MAKİNE ÖĞRENMESİ YÖNTEMLERİ.....	42
2.1.1. Denetimli Makine Öğrenmesi	42

2.1.2. Denetimsiz Makine Öğrenmesi	42
2.1.3. Yarı Denetimli Makine Öğrenmesi	43
2.1.4. Pekiştirmeli Makine Öğrenmesi	43
2.2. MAKİNE ÖĞRENMESİ ALGORİTMALARI.....	43
2.2.1. Gauss Süreç Regresyonu (GPR).....	44
2.2.2. Destek Vektör Regresyonu (SVR)	46
2.2.3. Karar Ağaçları (DT)	49
2.2.3.1. Entropi (Entropy) ve bilgi kazancı (information gain)	50
2.2.3.2. Bilgi kazancı	50
2.2.3.3. Gini impurity (Gini safsızlığı)	51
2.2.3.4. Regresyon ağacı ve ortalama kare hata	51
2.2.3.5. Karar ağacı inşası ve optimizasyonu (pruning)	52
2.2.4. Topluluk Öğrenmeleri (EL).....	52
2.2.5. Yapay Sinir Ağları (YSA)	53
2.3. İSTATİSTİKSEL YÖNTEM: ÇOK DEĞİŞKENLİ DOĞRUSAL REGRESYON (MLR)	
.....	55
2.4. VERİ TOPLAMA SÜRECİ	56
2.5. DEĞİŞKENLERİN TREND ANALİZİ	58
2.5.1. Tarım Arazisi (% Arazi Alanı)	58
2.5.2. Tarım, Ormancılık ve Balıkçılık, Katma Değer (% Gsyih).....	59
2.5.3. Kentsel Nüfus Artışı (Yıllık %).....	60
2.5.4. Tarımda İstihdam (% Toplam İstihdam)	61
2.5.5. Sulanan Tarım Arazisi (% Toplam Tarım Arazisi)	63
2.5.6. Tarımsal Ham Madde İhracatı (% Toplam Mal İhracatı).....	64
2.5.7. Bitkisel Üretim Endeksi (2014-2016 = 100)	65
2.5.8. Gıda Üretim Endeksi (2014-2016 = 100)	66
2.5.9. Gübre Tüketimi (% Gübre Üretimi)	67
2.5.10. Yıllık Tatlı Su Çekimi, Tarım (% Toplam Tatlı Su Çekimi).....	68
2.5.11. Kentsel Nüfus (% Toplam Nüfus)	69
2.5.12. Tarım Kredisi (Milyon USD)	71
2.6. EKSİK VERİ ANALİZİ VE TAMAMLAMA	72
2.7. İSTATİSTİKSEL ÖZET VE DEĞERLENDİRME	73
2.7.1. Korelasyon Analizi: Tarımsal ve Ekonomik Faktörler	74
2.7.1.1. Pozitif korelasyon gösteren değişkenler	75
2.7.1.2. Negatif korelasyon gösteren değişkenler.....	75
2.7.2. Ana Bileşen Analizi (PCA)	77
2.7.3. Tanımlayıcı İstatistikler	80
2.8. VERİ NORMALİZASYONU VE ÖLÇEKLEME.....	82
ÜÇÜNCÜ BÖLÜM.....	86
3. BULGULAR	86
3.1. GAUSS SÜREÇ REGRESYONU (GPR) YÖNTEMİNİN BULGULARI	87
3.2. DESTEK VEKTÖR REGRESYONU (SVR) YÖNTEMİNİN BULGULARI.....	89
3.3. KARAR AĞACI YÖNTEMİNİN BULGULARI.....	90
3.4. TOPLULUK ÖĞRENMELERİ YÖNTEMİ BULGULARI	92
3.5. YAPAY SİNİR AĞLARI (YSA) YÖNTEMİNİN BULGULARI	93
3.6. ÇOKLU DOĞRUSAL REGRESYON (MLR) YÖNTEMİNİN BULGULARI.....	95

3.7. GELİŞTİRİLEN MODELLERİN KARŞILAŞTIRILMASI.....	96
SONUÇ, TARTIŞMA VE ÖNERİLER.....	100
Sonuç	100
Tartışma	101
Öneriler	103
KAYNAKÇA.....	105
ÖZ GEÇMİŞ	114



TABLÖLAR

Tablo 1: GPR Kernel Fonksiyonlarının Matematiksel İfadeleri	44
Tablo 2: SVR Çekirdek Fonksiyonlarının Matematiksel İfadeleri.....	48
Tablo 3: Değişkenler, Birimleri ve Kaynakları	57
Tablo 4: Bağımsız Değişkenler İçin VIF Değerleri.....	76
Tablo 5: PCA Analiz Sonuçları	78
Tablo 6: Temel Bileşenler ve Değişken Katkıları	79
Tablo 7: Tanımlayıcı İstatistikler	80
Tablo 8: GPR Modeli Performans Ölçütleri.....	88
Tablo 9: SVR Modeli Sonuçları	90
Tablo 10: Karar Ağacı Modeli Performans Ölçütleri	91
Tablo 11: Topluluk Öğrenmeleri Modelinin Performans Ölçütleri.....	92
Tablo 12: YSA Modeli Performans Ölçütleri.....	94
Tablo 13: MLR Modelinin Performans Ölçütleri.....	96
Tablo 14: Karşılaştırmalı Performans Ölçütleri	96

ŞEKİLLER

Şekil 1: Türkiye’de Kentsel ve Kırsal Nüfus Değişimi	19
Şekil 2: Ekonomik Yönden Aktif Nüfusun Sektörel Dağılışı	20
Şekil 3: Türkiye’de işsizlik oranı	20
Şekil 4: Gayri Safi Yurtiçi Hasıla Büyüme Hızı ve Tarımın Gayri Safi Yurtiçi Hasıla İçindeki Payı	22
Şekil 5: Merkezi Yönetim Bütçe Harcamaları İçinde Tarımsal Destekleme Ödemeleri ve Bütçe İçindeki Paylar	29
Şekil 6: Yapay Sinir Ağı Modeli.....	54
Şekil 7: Türkiye'deki Tarım Arazisi Kullanımının Yıllık Değişimi (% Arazi Alanı).....	58
Şekil 8: Türkiye’de Tarım, Ormancılık ve Balıkçılığın GSYİH'ye Katkısı (2000-2022)	59
Şekil 9: Kentsel Nüfus (% Toplam Nüfus) Trend Grafiği (2000-2022)	61
Şekil 10: Tarımda İstihdam (%Toplam İstihdam) Trend Grafiği (2000-2022)	62
Şekil 11: Sulanan Tarım Arazisi (% Toplam Tarım Arazisi) Trend Grafiği (2000-2022)	63
Şekil 12: Tarımsal Ham Madde İhracatı (%) Trend Grafiği (2000-2022)	64
Şekil 13: Bitkisel Üretim Endeksi (2014-2016=100) Trend Grafiği (2000-2022)	65
Şekil 14: Gıda Üretim Endeksi (2014-2016=100) Trend Grafiği (2000-2022)	66
Şekil 15: Gübre Tüketimi (% Gübre Üretimi) Trend Grafiği (2000-2022)	67
Şekil 16: Tatlı Su Çekimi (% Tarım) Trend Grafiği (2000-2022)	69
Şekil 17: Kentsel Nüfus (%Toplam Nüfus) Trend Grafiği (2000-2022)	70
Şekil 18: Tarım Kredisi (Milyon USD) Trend Grafiği (2000-2022)	71
Şekil 19: PCA Temel Bileşenlerinin Açıklanan Varyans Oranları	79
Şekil 20: Geliştirilen Modellerin R2 (a) Değerleri RMSE (b) Değerlerinin Karşılaştırılması	98

KISALTMALAR

ARDL	: Otoregresif Dağıtılmış Gecikmeli Model
BÜE	: Bitkisel Üretim Endeksi
DGD	: Doğrudan Gelir Desteği
DIK	: Doğu Anadolu, İç Anadolu ve Karadeniz
DT	: Karar Ağaçları
EL	: Topluluk Öğrenmeleri
GAM	: Genelleştirilmiş Toplamalı Model
GSMH	: Gayri Safi Milli Hasıla
GSYİH	: Gayri Safi Yurtiçi Hasıla
GT	: Gübre Tüketimi
GÜE	: Gıda Üretim Endeksi
GPR	: Gauss Süreç Regresyonu
IMF	: Uluslararası Para Fonu
KD	: Katma Değer
KNA	: Kentsel Nüfus Artışı
KNN	: K-En Yakın Komşu Algoritması
KOBİ	: Küçük ve Orta Büyüklükteki İşletmeler
MAE	: Ortalama Mutlak Hata
MAPE	: Ortalama Mutlak Yüzde Hatası
MLR	: Çok Değişkenli Doğrusal Regresyon
MLR	: Çoklu Doğrusal Regresyon
MSE	: Mean Squared Error
MSE	: Ortalama Kare Hata
PCA	: Temel Bileşen Analizi
RMSE	: Kök Ortalama Kare Hata
STA	: Sulanan Tarım Arazisi
SVM	: Destek Vektör Regresyonu
SVR	: Destek Vektör Regresyonu
TA	: Tarım Arazisi
THMİ	: Tarımsal Ham Madde İhracatı
Tİ	: Tarımda İstihdam
TK	: Tarım Kredisi
TKDK	: Tarım ve Kırsal Kalkınmayı Destekleme Kurumu
TL	: Türk Lirası

TRUP	: Tarım Reformu Uygulama Projesi
TSC	: Yıllık Tatlı Su Çekimi
USD	: Amerikan Doları
VAR	: Vektör Otoregresyon
VIF	: Varyans Enflasyon Faktörü
WTO	: Dünya Ticaret Örgütü
YSA	: Yapay Sinir Ağları

SİMGELER

C	: ceza katsayısı
ϵ	: ceza boyutu
I	: birim matris
p	: korelasyon katsayısı
R²	: determinasyon katsayısı
X	: orijinal veri değeri

GİRİŞ

Tarım, tarih boyunca her toplum için son derece önemli bir ekonomik faaliyet olmuştur. Bunun temel nedeni, insanların en temel ihtiyaçlarından biri olan beslenmeyi doğrudan karşılamasıdır. Ekonomik kalkınma, her toplumun temel hedeflerinden biridir ve tarım, bu kalkınma için gerekli kaynakları sağlama noktasında kritik bir rol oynamaktadır. Özellikle gelişmekte olan ülkelerde, önemli bir kalkınma faktörü olarak öne çıkmaktadır. Gıda ihracatı ve ithalatı, ülkeler için hem önemli bir gelir kaynağı hem de döviz tasarrufu açısından büyük bir öneme sahiptir. Bunun yanı sıra tarım sektörü, geniş bir istihdam alanı yaratarak toplumsal refaha katkıda bulunmaktadır (Kılıçalp vd., 2001).

Türkiye'nin ekonomik ve sosyal kalkınmasında tarım sektörü önemli bir rol oynamaktadır. Uzun yıllar boyunca ekonominin en önemli unsuru olmuştur, ancak son yıllarda sanayi, ticaret ve hizmet sektörlerindeki hızlı gelişmeler nedeniyle önemi azalmıştır. Bununla birlikte, tarım sektörü gıda üretimi ve beslenmeyle doğrudan ilişkili olduğundan tarımda çalışan büyük bir işgücüyle milli gelire katkı sağlamaktadır. Ayrıca, tarım sektörü, sanayi sektörü için hammadde sağlama, sağlıklı bir çevre yaratma ve sürdürülebilirlik gibi konularda da önemli bir rol almaktadır. Bu nedenle, ekonomik ve sosyal açıdan önemli olmakla beraber ülke nüfusunun tamamını da ilgilendiren önemli bir alandır (Kazgan, 2003).

Tarım sektörü, bir ülkenin ekonomik yapısı içinde çeşitli kriterlere göre değerlendirilebilmektedir. Bu kriterler arasında sektörün milli gelire katkısı, ülkenin kendi kendine yeterliliği, ihracat ve ithalat performansı, sanayi sektörüne sağladığı girdiler, istihdamdaki payı, talep oluşturma kapasitesi ve diğer sektörlerle olan önemi gibi faktörler yer almaktadır (Günaydın, 2006).

Yatırımcılar ve girişimciler, kredi yardımıyla gerçekleştirdikleri yatırımlarla ekonomik büyümeye katkı sağlamaktadır. Krediyle yapılan yatırımlar, yatırımlarda pozitif bir artışa katkı sağlayarak, bu doğrultuda istihdamda artışa katkı sunmaktadır. Ek olarak kredi, ekonomik büyümenin temel finansal kaynağı olarak kabul edilmektedir (Selçuk, 2015).

Tarım sektöründeki finansman talebi, gelişmiş ülkelerde organize tarımsal kredi kuruluşları tarafından karşılanırken, gelişmekte olan ülkelerde ve Türkiye'de organize olmayan kredi kuruluşları tarafından sağlanmaktadır. Tarımsal krediler genellikle devlet tarafından desteklenen yerel bankalar, ihtisaslaşmış kredi kuruluşları ve kooperatifler tarafından sağlanmaktadır (Taşkiran & Özudoğru, 2010).

Tarımsal işletmelerin büyümesi ve uzmanlaşmasıyla birlikte, sermaye ve kredi ihtiyaçlarında artış görülmektedir. Bu ihtiyaçları karşılamak amacıyla işletmeler, dışarıdan girdi

satın alarak üretim faaliyetlerini sürdürmektedir. İşletmelerin büyümesi hem üretim hacmini artırmakta hem de sermayeden daha fazla pay alarak kârlılıklarını artırma potansiyeli sunmaktadır. Tarımsal krediler, doğru amaçlarla kullanıldığında, işletmelerin verimliliğini ve kârlılığını artırarak sektöre önemli bir katkı sağlamaktadır. Bu durum, işletmelerin daha fazla üretim yapabilmelerini mümkün kılarak tarım sektörünün genel gelişimine destek olmaktadır (Doll & Orazem, 2005).

Bu bağlamda, tarımsal işletmelerin finansal ihtiyaçlarını karşılamak için modern teknolojiler ve yöntemler giderek daha fazla önem kazanmaktadır. Özellikle makine öğrenmesi gibi yenilikçi teknikler, finansal karar alma süreçlerinde etkin bir rol oynamaya başlamıştır. Makine öğrenmesi, finansal karar alma süreçlerinde son yıllarda önemli bir konuma gelmiştir. Bu durum, makine öğrenmesinin sunduğu model oluşturma, veri analizi ve yalnızca veri üzerinden öngörülerde bulunma gibi avantajlardan kaynaklanmaktadır. Bu tekniklerle, finansal kararlar daha hızlı ve doğru bir şekilde alınabilir hale gelmiştir. Bununla birlikte, makine öğrenmesinin etkin kullanımı bazı zorlukları da beraberinde getirmektedir. Örneğin, doğru veri setinin seçimi, modelin uygun parametrelerinin belirlenmesi ve bu sürecin sürekli iyileştirilmesi kritik öneme sahiptir. Ancak, bu zorlukların üstesinden gelindiğinde, finans sektöründe makine öğrenmesi teknikleriyle risk analizi, portföy optimizasyonu ve diğer finansal kararlar daha verimli bir şekilde yönetilebilmekte ve sektöre önemli katkılar sağlanmaktadır (Doğan & Türe, 2022).

Makine öğrenmesindeki bu ilerlemeler, sadece finans sektörüyle sınırlı kalmayıp farklı sektörlerde de etkili bir şekilde kullanılmaktadır. Bu durum, teknolojinin yaşamın birçok alanında yenilikçi çözümler sunma potansiyelini artırmaktadır. Teknolojik ilerlemeler, makine öğrenmesi alanında büyük bir dönüşüm yaratmıştır. Bu gelişmeler sayesinde sistemler, insanlar tarafından yapılan birçok işi daha etkili ve hızlı bir şekilde gerçekleştirebilmektedir. Örneğin, ses ve nesne tanıma gibi alanlarda, bazı makine öğrenmesi uygulamaları insan performansını geride bırakmıştır. Bunun dikkat çekici bir örneği, el yazısıyla yazılmış rakamları tanımlama üzerine yapılan bir çalışmadır; burada, makine öğrenmesi sistemleri insanlardan daha yüksek doğruluk oranlarına ulaşmıştır. Bu tür ilerlemeler, geniş veri kaynaklarına erişim ve yüksek işlem gücüne sahip teknolojilerin etkili kullanımıyla mümkün hale gelmiştir. Makine öğrenmesindeki bu gelişmeler, yapay zekâ teknolojilerinin daha geniş bir yelpazede kullanılmasını sağlayarak birçok sektöre değer katmaktadır (Markoff, 2015).

Araştırmanın Konusu ve Problemi

Bu çalışma Türkiye'de tarım sektörüne sağlanan kredilerin tahmin edilmesi amacıyla makine öğrenmesi modellerinin uygulanmasını ele almaktadır. Tarım sektörü, Türkiye

ekonomisi için stratejik bir öneme sahiptir ve sağlanan krediler, üretim kapasitesini artırmak, kırsal kalkınmayı desteklemek ve gıda güvenliğini sağlamak açısından kritik bir rol oynamaktadır. Bu bağlamda, tarım sektörüne tahsis edilen kredi miktarlarının doğru bir şekilde tahmin edilmesi hem kamu politikalarının etkinliği hem de finansal kaynakların verimli kullanımı açısından önem arz etmektedir. Araştırma, tarımsal kredi tahminine yönelik olarak makine öğrenmesi yöntemlerini kullanmayı ve bu yöntemlerin doğruluk ve güvenilirlik açısından performanslarını değerlendirmeyi amaçlamaktadır. Kredi tahminine etki eden çok sayıda ekonomik, çevresel ve sosyal değişkenin modellenmesi, araştırmanın temel odak noktalarından birini oluşturmaktadır. Ek olarak bu çalışma, farklı makine öğrenmesi algoritmalarını karşılaştırarak, tarım sektöründe kredi tahmininde en etkili yöntemi belirlemeyi hedeflemektedir.

Tarım sektöründe finansal kaynakların etkin bir şekilde tahsis edilmesi, üretimin sürdürülebilirliği ve ekonomik kalkınma açısından hayati bir öneme sahiptir. Ancak, tarımsal kredi miktarlarının tahmini, çok boyutlu ve karmaşık verilerin varlığı nedeniyle zorlu bir problem olarak ortaya çıkmaktadır. Tarımsal kredilere etki eden faktörler arasında tarımsal üretim verileri, ekonomik göstergeler, sosyal dinamikler ve çevresel değişkenler yer almakta olup, bu faktörler arasındaki doğrusal olmayan ilişkiler, geleneksel istatistiksel yöntemlerin etkinliğini sınırlandırmaktadır. Ayrıca, iklim değişikliği, ekonomik dalgalanmalar ve demografik değişimler gibi dinamik koşullar, kredi tahmininde belirsizliklere yol açarak güvenilir sonuçlar elde etmeyi güçleştirmektedir. Yanlış tahminler, finansal kaynakların yetersiz veya aşırı tahsisine neden olarak hem tarımsal üretimi hem de kırsal ekonomiyi olumsuz etkileyebilecektir. Bu doğrultuda, tarımsal kredi talebinin doğru bir şekilde öngörülmesi, kırsal kalkınmayı desteklerken aynı zamanda tarım sektörünün ihtiyaçlarına uygun politikalar geliştirilmesi için kritik bir gerekliliktir. Geleneksel yöntemlerin büyük ve karmaşık veri setlerini işleme konusundaki yetersizliği, makine öğrenmesi modellerinin bu alandaki potansiyelini öne çıkarmaktadır. Ancak, bu modellerin tarımsal kredi tahminine yönelik performanslarının kapsamlı bir şekilde değerlendirilmesi ve uygulanabilirliğinin optimize edilmesi gerekmektedir. Araştırmanın temel problemi, Türkiye’deki tarım sektörüne sağlanan kredilerin tahmini için en etkili makine öğrenmesi yöntemini belirlemek ve bu yöntemlerin doğruluk, güvenilirlik ve adaptasyon kabiliyetlerini optimize etmeye odaklanmaktadır.

Araştırmanın Amacı

Ülkemizde tarım sektöründeki gelişme ve büyüme için tarımsal kredilerin etkili bir şekilde yönetilmesi krediyi sağlayan kuruluşlar açısından çok önemlidir. Tarımsal kredilerin

gelirleri etkileyen çeşitli faktörler ve bu faktörlerin analiz edilmesinin zorluğu, makine öğrenmesi yöntemlerinin kullanılmasıyla daha doğru kredi kararları alınmasına destek olmaktadır. Ülkelerin tarımsal kredi için ayıracakları bütçeyi belirlemeleri için bir karar destek sistemi kullanmaları gerekmektedir.

Türkiye için yıllara göre geçmiş veriler kullanılarak gelecekteki tarım kredilerini tahmin edecek yapay zekâ tabanlı bir model geliştirilmesi, tarım sektörünün dinamik ve riskli yapısı göz önünde bulundurulduğunda büyük önem taşımaktadır. Geliştirilen yapay zekâ tabanlı model, kredi taleplerini doğru bir şekilde öngörerek, çiftçilere zamanında ve etkin destek sağlanmasına, kaynakların daha verimli dağılmasına, tarım politikalarının daha doğru yönlendirilmesine ve ekonomik dalgalanmalara karşı hazırlıklı olunmasına katkıda bulunabilecektir. Ayrıca, doğal afetler ve iklim değişikliği gibi riskler dikkate alınarak finansal çözümlerin optimize edilmesi, sektördeki verimliliğin artması ve ekonomik krizlere karşı dayanıklılığın güçlenmesi açısından kritik bir rol oynamaktadır.

Dünyanın tarıma ayırdığı finans miktarını belirlemek, gıda güvenliği, sürdürülebilir kalkınma, ekonomik büyüme ve çevresel etki gibi kritik alanlarda doğru kararlar alınmasını sağlamaktadır. Tarıma yapılan yatırımlar, üretim kapasitesini artırır, gıda fiyatlarını stabilize eder, kırsal kalkınmayı destekler ve iklim değişikliğiyle mücadelede etkili çözümler üretmeyi sağlamaktadır. Ayrıca, bu veriler, küresel ticaretin yönünü, tarım politikalarını ve kaynakların daha verimli kullanılmasını belirlemede rehberlik etmektedir. Yatırımların hangi alanlara yönlendirileceğini bilmek, daha sürdürülebilir ve verimli bir tarım sektörü için stratejik planlamayı mümkün kılmaktadır.

Türkiye'nin tarıma ayırdığı kaynağı tespit etmek, tarım sektörü ile ilgili kararlar alırken büyük bir öneme sahiptir. Bu tespiti yapmak, sektöre yapılan yatırımın ne kadar yeterli olduğunu, hangi alanlarda eksikliklerin veya fazlalıkların olduğunu göstermektedir. Tarımın sürdürülebilirliği, verimliliği ve çiftçilerin yaşam standartları büyük ölçüde devletin bu alana sağladığı finansal desteğe bağlıdır. Tarıma yapılan harcamaların doğru bir şekilde izlenmesi, stratejik kararların alınmasında ve kaynakların etkin bir şekilde dağıtılmasında yardımcı olmaktadır.

Makine öğrenmesi modelleri kullanılarak, bu verileri analiz ederken sadece geçmiş harcamaları değil, aynı zamanda ekonomik, çevresel ve sosyo-politik faktörleri de göz önünde bulundurarak daha doğru tahminler yapabilme imkânı sağlamaktadır. Makine öğrenmesi algoritmaları, büyük ve karmaşık veri setlerini analiz ederek gelecekteki harcama trendlerini, bölgesel farkları ve öncelikli yatırım alanlarını tespit edebilmektedir. Ayrıca, ekonomik değişkenler, iklim koşulları ve tarımsal üretim verilerini dikkate alarak daha dinamik ve doğru

bir model oluřturulmasına imkân tanımaktadır. Böylece, tarıma yapılacak yatırımların daha verimli bir řekilde planlanması, gereksiz harcamaların önlenmesi, deęiřkenlerin kredi miktarını nasıl etkilediğini ve kaynakların daha etkin bir řekilde kullanılması saęlanabilmektedir.

Türkiye gibi geliřmekte olan bir ÷lkede tarıma yapılan harcamaların önceden öngör÷lmesi, tarım sektörünün sürdür÷lebilirlięi, verimlilięi ve ekonomik kalkınma için kritik öneme sahiptir. Tarıma yapılan yatırımlar, üretim kapasitesini artırmak, çiftçilerin finansal ihtiyaçlarını karřılamak ve gıda güvenlięini saęlamak için gereklidir. Ayrıca, iklim deęiřiklięi ve doęal afetler gibi risklere karřı tarım sektörü desteklenmeli ve bu harcamalar etkili bir řekilde yönlendirilmelidir. Tarımda yapılan harcamaların elde edilen veriler ışıęında tarımsal yatırım kararların doęru bir řekilde tahmin edilmesi, kaynakların verimli kullanılması, kırsal kalkınmanın hızlandırılması ve tarım politikalarının etkinlięinin artırılması için önem arz etmektedir. Bu öngörü, ekonomik istikrarı saęlamaya ve tarımsal üretimin sürdür÷lebilirlięine katkı saęlamaktadır.

Tarım kredi miktarını etkileyen faktörler tarım sektörü doęası gereęi birçok dıřsal ve içsel etkene duyarlıdır. Tarımsal üretim, iklim kořulları, ürün fiyatları, verimlilik oranları, doęal afetler, tarımsal teknoloji kullanımı, pazar talebi gibi deęiřkenler, çiftçilerin finansal ihtiyaçlarını doğrudan etkilemektedir. Bu bağlamda, tarım kredileri, çiftçilerin üretim yapabilmesi için gerekli finansmanı saęlamada önemli bir araçtır ve bu kredilerin miktarını doęru bir řekilde tahmin edebilmek için bu deęiřkenlerin etkilerini analiz etmek gerekmektedir.

Makine öğrenmesi modelleri ile istatistiksel modeller karřılařtırıldığında bazı farklar ortaya çıkmaktadır. İstatistiksel modeller genellikle doğrusal iliřkiler üzerine inşa edilirken, makine öğrenmesi modelleri daha karmařık ve doğrusal olmayan iliřkileri öğrenebilmektedirler. Makine öğrenmesi modelleri, geçmiş verilerden öğrenerek daha doęru tahminler yapabilir ve karmařık iliřkileri daha başarılı bir řekilde çözüme ulařtırabilir. İstatistiksel modeller sınırlı sayıda veri setiyle sonuçlar saęlayabilirken, makine öğrenmesi modelleri büyük ve çeřitli veri setleriyle daha etkili çalışmaktadır. Makine öğrenmesi modelleri, verilere dayalı olarak kendini geliştirme yeteneęine sahiptir ve deęiřen kořullara hızla uyum saęlayabilmektedir. Tahmin ve öngörü performansı açısından, makine öğrenimi modelleri daha derin içgör÷ler elde edebilir ve daha yüksek doęrulukla tahminler yapabilir. Örneęin, tarımsal kredi miktarını mevsimsel etkiler ve iklim deęiřiklikleri gibi dinamik faktörleri dikkate alarak daha doęru bir řekilde tahmin yürüterek daha doęru sonuçlar ortaya koyabilmektedir.

Bu doğrultuda, makine öğrenmesi modellerinin saęladığı avantajlar, tarımsal kredi tahmini gibi çok boyutlu ve karmařık problemlerin çözümünde daha belirgin bir řekilde öne

çıkılmaktadır. Özellikle, tarım sektöründe kullanılan kredilerin tahsisi ve yönetimi gibi kritik süreçlerde bu modellerin yüksek doğruluk oranı ve değişen koşullara uyum sağlama yeteneği, karar alıcılara daha etkin ve stratejik planlamalar yapma imkânı sunmaktadır. Ayrıca, ekonomik ve çevresel koşullardaki dinamik değişimlerin etkisi dikkate alındığında, makine öğrenmesi yaklaşımlarının yalnızca geçmiş verilerden öğrenmekle sınırlı kalmayıp, gelecekte ortaya çıkabilecek olası değişimlere yönelik öngörü ve proaktif çözümler sunma kapasitesine sahip olduğu görülmektedir. Bu bağlamda, kaynakların daha etkin ve verimli bir şekilde kullanılması sağlanırken, aynı zamanda tarım sektörü paydaşlarının değişen ihtiyaçlarına hızlı ve esnek bir şekilde yanıt verilmesine de olanak tanınmaktadır (Liakos vd., 2018).

Bu çalışmanın temel amacı, Türkiye’de tarım sektörüne sağlanan kredilerin (milyon ABD doları) tahmin edilmesine yönelik yüksek doğruluk ve güvenilirlik sağlayan makine öğrenmesi modelleri geliştirmektir. Tarım sektörü, Türkiye’nin ekonomik ve sosyal yapısında stratejik bir öneme sahiptir. Sektör, gıda güvenliğinin sağlanması ve kırsal kalkınmanın desteklenmesinde kritik bir rol üstlenmektedir. Ancak, sektördeki değişken ekonomik, çevresel ve sosyal faktörler, tarımsal kredi tahsis ve yönetim süreçlerinde belirsizliklere yol açmaktadır. Bu bağlamda, bu çalışmada makine öğrenmesi yöntemleri kullanılarak söz konusu belirsizliklerin en aza indirilmesi ve kredilerin daha etkin bir şekilde yönetilmesi hedeflenmektedir. Bu amaç doğrultusunda çalışmada, Gauss Süreç Regresyonu (GPR), Destek Vektör Regresyonu (SVR), Karar Ağaçları (DT), Topluluk Öğrenme Yöntemleri (EL), Yapay Sinir Ağları (YSA) gibi çeşitli makine öğrenmesi algoritmaları ve istatistiksel yöntem olarak Çok Değişkenli Doğrusal Regresyon (MLR) kullanılmıştır.

Araştırmanın Önemi ve Gerekçesi

Tarım sektörü, Türkiye'nin ekonomik ve sosyal yapısında stratejik bir konuma sahiptir. Bu sektör, gıda güvenliğinin sağlanması, kırsal kalkınmanın desteklenmesi ve ekonomik istikrarın korunmasında kritik bir rol üstlenmektedir. Ancak, tarım sektörüne sağlanan finansal kaynakların doğru tahsisi ve etkin yönetimi, sektörel sürdürülebilirlik ve verimlilik açısından büyük önem taşımaktadır. Tarımsal kredilerin tahsisi hem üretim faaliyetlerini desteklemek hem de tarım ekonomisinin değişen ihtiyaçlarına uygun çözümler sunmak açısından önemli bir araçtır. Bu bağlamda, kredilerin doğru bir şekilde tahmin edilmesi, kaynakların en uygun şekilde dağıtılmasını sağlarken, aynı zamanda kamu politikalarının daha etkin bir şekilde uygulanmasına da katkıda bulunur. Çalışma, makine öğrenmesi gibi yenilikçi teknolojilerin tarımsal kredi tahmininde kullanılmasını ele alarak, mevcut yaklaşımların ötesinde daha doğru ve güvenilir tahmin modelleri geliştirilmesine olanak tanımayı amaçlamaktadır. Bu durum hem

akademik literatüre katkı sunmak hem de politika yapıcıların karar alma süreçlerini desteklemek açısından çalışmayı önemli kılmaktadır.

Tarımsal kredi tahmini, ekonomik göstergeler, çevresel değişkenler ve sosyal dinamikler gibi çok boyutlu ve karmaşık veri yapılarını içeren bir problem olarak öne çıkmaktadır. Geleneksel tahmin yöntemleri, bu karmaşıklığı tam anlamıyla modelleyememekte ve doğrusal olmayan ilişkileri yeterince ele alamamaktadır. Bu durum, kredi tahmini süreçlerinde belirsizliklere ve kaynak yönetiminde etkinlik kaybına yol açmaktadır. Makine öğrenmesi teknikleri, büyük veri setlerini analiz etme, doğrusal olmayan ilişkileri modelleme ve farklı koşullara adaptasyon sağlama kapasitesine sahiptir. Dolayısıyla, makine öğrenmesi tabanlı yaklaşımlar, tarımsal kredi tahminine yönelik daha hassas ve güvenilir sonuçlar elde edilmesini mümkün kılmaktadır. Bu çalışmanın gerekçesi, mevcut yöntemlerin sınırlılıklarını aşarak tarım sektörüne sağlanan kredilerin daha etkin bir şekilde yönetilmesi ve sürdürülebilir kalkınma hedeflerine katkı sağlama ihtiyacına dayanmaktadır. Ayrıca, bu çalışma, makine öğrenmesi modellerinin tarım sektöründeki uygulama potansiyelini ortaya koyarak hem akademik hem de pratik düzeyde önemli bir boşluğu doldurmayı hedeflemektedir.

Araştırmanın Sınırlılıkları

Bu araştırma, makine öğrenmesi modelleri kullanarak Türkiye’deki tarım sektörüne sağlanan kredilerin tahmin edilmesine yönelik önemli bir katkı sunmayı hedeflese de çalışmanın belirli sınırlılıkları bulunmaktadır. İlk olarak, araştırmada kullanılan verilerin doğruluğu ve bütünlüğü, sonuçların güvenilirliğini doğrudan etkileyebilmektedir. Bazı değişkenlere ilişkin eksik ya da güncel olmayan verilerin bulunması, model performansında sınırlamalara yol açabilecektir. Ayrıca, veri setlerine erişim kısıtlılıkları, çalışmanın kapsamını daraltabilecek ve sonuçların genelleştirilebilirliğini etkileyebilecektir. İkinci olarak, kullanılan makine öğrenmesi modellerinin performansı, veri kümesi, hiperparametre optimizasyon teknikleri ve algoritmaların yapısına bağlıdır; bu durum, elde edilen sonuçların genelleştirilebilirliğini sınırlayabilecektir. Üçüncü olarak, tarım sektörünün ekonomik dalgalanmalara, çevresel değişimlere ve iklim koşullarına yüksek derecede duyarlı olduğu göz önüne alındığında, geçmiş verilere dayalı olarak geliştirilen modellerin gelecekteki değişimleri tam anlamıyla yansıtamayabileceği bir diğer sınırlılık olarak değerlendirilmektedir. Son olarak, sosyal ve politik faktörler araştırmada sınırlı bir kapsamda ele alınmıştır. Tarımsal destek politikalarındaki değişiklikler, uluslararası ticaret koşulları ve kırsal kalkınma stratejilerinin kredi tahsisi üzerindeki etkileri daha geniş bir inceleme gerektirmektedir. Bu sınırlılıklar, çalışmanın bulgularını değerlendirirken dikkate alınması gereken unsurlar olup, araştırma, gelecekte daha kapsamlı analizler yapılmasına ışık tutmayı amaçlamaktadır.

Varsayımlar

Bu araştırmada, Türkiye’de tarım sektörüne sağlanan kredilerin tahmin edilmesine yönelik makine öğrenmesi modellerinin geliştirilmesi sürecinde belirli varsayımlardan hareket edilmiştir. Çalışmanın dayandığı temel varsayımlar aşağıdaki şekilde sıralanabilir:

1. Araştırmada kullanılan veri setlerinin doğru, güvenilir ve Türkiye’deki tarım sektörünü temsil edecek nitelikte olduğu varsayılmıştır. Veri kaynaklarının güvenilirliği, model sonuçlarının doğruluğu açısından kritik bir öneme sahiptir. Bu nedenle, kullanılan ekonomik, çevresel ve sosyal değişkenlerin, tarımsal kredi miktarlarını etkileyen temel faktörleri yansıttığı kabul edilmiştir.
2. Araştırmada kullanılan bağımsız değişkenler, regresyon analizi ve Temel Bileşen Analizi (PCA) yardımıyla belirlenmiş ve tarımsal kredi tahmini üzerinde anlamlı bir etkiye sahip oldukları varsayılmıştır. Ancak, PCA'nın veri boyutunu azaltırken orijinal değişkenlerin anlamını ve bağlamını kaybetme riski bulunmaktadır. Bu, bileşenlerin yorumlanabilirliğini zorlaştırabilir ve modelin sonuçlarını doğrudan gerçek dünya değişkenleri ile ilişkilendirmeyi sınırlandırabilir. Ayrıca, bu yöntemlerle seçilen değişkenler, yalnızca kullanılan veri seti ve analitik yaklaşımlara dayanmakta olup, diğer potansiyel faktörlerin göz ardı edilmesine yol açabilir. Veri setinin kapsamı ve doğruluğu ile seçilen değişkenler arasındaki olası multikolinearite ve diğer istatistiksel kısıtlılıklar, modelin güvenilirliğini etkileyen faktörler arasında yer almaktadır.
3. Çalışmada kullanılan veri setlerinin zamansal ve mekânsal olarak tutarlı olduğu varsayılmıştır. Bu durum, modelin güvenilir sonuçlar üretmesi için önemli bir varsayımı teşkil etmektedir.
4. Çalışmada kullanılan makine öğrenmesi algoritmalarının, tarımsal kredi tahmini gibi karmaşık ve doğrusal olmayan ilişkiler içeren problemlerde genel geçerliliği olduğu varsayılmıştır. Algoritmaların performansı, hiperparametre optimizasyonu ve uygun veri işleme teknikleri ile artırılabilir kabul edilmiştir.
5. Çalışma kapsamında kullanılan ekonomik ve çevresel faktörlerin, geçmişte gözlemlenen veriler ışığında gelecekte benzer eğilimler göstereceği varsayılmıştır. Bu varsayım, veri setlerinin modele uygunluğunu ve tahminlerdeki güvenilirliği sağlamak için kritik öneme sahiptir.
6. Araştırma sürecinde, tarımsal kredi tahminine etki edebilecek beklenmeyen dış faktörlerin (örneğin, ani ekonomik krizler, politika değişiklikleri, doğal afetler) analiz

kapsamı dışında kaldığı varsayılmıştır. Bu tür faktörlerin varlığı, model sonuçlarını etkileyebilecek ancak öngörülemeyen değişkenler olarak değerlendirilmiştir.

Bu araştırmada belirtilen varsayımlar, çalışmanın metodolojik temelini oluşturarak güvenilir sonuçlar elde edilmesini amaçlamaktadır. Ancak, ekonomik, çevresel ve sosyal değişkenlerin dinamik yapısı ile beklenmeyen dış faktörler, bulguların genelleştirilebilirliği üzerinde belirli sınırlılıklar yaratabilmektedir. Bu nedenle, çalışmanın sonuçları yorumlanırken bu varsayımlar dikkate alınmalı ve gelecek araştırmalarda bu varsayımlar genişletilerek daha kapsamlı analizlere yer verilmelidir.



BİRİNCİ BÖLÜM

1. KURAMSAL ÇERÇEVE

1.1. TARIM SEKTÖRÜNÜN GELİŞİMİ

Tarım, insanların temel ihtiyaçlarını karşılamak amacıyla insanlık tarihiyle başlayan ve dünyanın en eski ekonomik faaliyetlerinden biridir. İnsanların beslenme ihtiyaçlarını karşılayan yaşamsal ürünlerin üretildiği bu alan, her ülke için vazgeçilmez bir öneme sahiptir. Tarım sadece bitkisel ve hayvansal ürünlerin üretimi ile sınırlı değil, aynı zamanda bu ürünlerin işlenmesi, geliştirilmesi ve yeni ürünlerin yaratılması da dahil olmak üzere çeşitli faaliyetleri kapsamaktadır. Tarım sektörü, ekonomiye sağladığı katkının yanı sıra kültürel ve toplumsal yaşamın şekillenmesinde de önemli bir rol oynamaktadır. Bugün bile bazı bölgelerde tarımsal faaliyetler toplayıcılıkla birlikte devam etmektedir. Tarım, insanların temel yaşam ihtiyaçlarını karşılamada hayati bir rol oynamaktadır (Direk, 2010).

1.1.1. Tarım Sektörünün Tarihsel Gelişimi

İnsanlığın gıda ihtiyacını karşılamak amacıyla tarımsal faaliyetler, başlangıçta sadece kendine yetmek üzere gerçekleştirilmiş, ilerleyen süreçte ise daha geniş kitlelerin gıdaya erişimini sağlamak ve tarımsal işletmelerin kâr hedeflerini karşılamak üzere çeşitlenmiştir. İnsanlık, doğası gereği ihtiyaçlarını karşılamaya yönelik sürekli bir çaba içerisinde. İnsanın en temel gereksinimlerinden biri olan beslenme ihtiyacını karşılamak amacıyla tarımsal faaliyetlerin ortaya çıkışı ve bu faaliyetlerin sürdürülebilirliği, stratejik bir önem taşımaktadır (Maslow, 1948).

İnsanlık tarihi boyunca, tarım sektörü, üretim faaliyetleri ve toprak mülkiyeti konularında farklı evrelerden geçmiştir. Tarımsal faaliyetler, avcılık ve toplayıcılıkla başlayan süreçte, zamanla daha planlı ve uzmanlaşmış tarım uygulamalarına dönüşmüştür. İnsanlar, tarih boyunca toprak ve hayvanlardan yararlanma konusunda çeşitli aşamalardan geçmiştir. Bu aşamalar; toplayıcılık, avcılık ve balıkçılık, ilkel tarım, geçimlik tarım, uzmanlaşmış tarım ve modern tarım dönemlerini kapsamaktadır (Direk, 2010, s. 18).

Toplayıcılık ve avcılık/balıkçılık, insanların ilk zamanlarda geçimlerini sağlama yöntemleri olarak kullanılmıştır. İnsanlar doğadan yiyecek toplayarak yaşamlarını sürdürmüşlerdir. Bu dönemde kökler, meyveler, hayvanlar gibi doğal kaynaklar tüketildikçe insanlar yeni bölgelere göç etmişlerdir. Daha sonra avcılık ve balıkçılık yöntemiyle geçim sağlanmıştır. İnsanlar avlanmak için aletler yaparak hayvanları yakalayıp tüketerek yaşamlarını devam ettirmişlerdir. Paleolitik dönem olarak adlandırılan bu dönemde insanlar göçebe olarak

yaşamını sürdürmüş ve hayvan göçlerini takip etmişlerdir. Ancak daha sonra göçebe yaşamından sıkılan insanlar evcilleştirilmiş hayvanlarla yerleşik bir hayata doğru yönelmeye başlamışlardır. Bu süreçte kümes hayvanları, koyun, keçi, at ve eşek gibi evcilleştirilmiş hayvanlar tercih edilmiştir. Bu şekilde insanlar, toplayıcılık ve avcılık/balıkçılık gibi atalarından miras kalan yaşam tarzlarından uzaklaşmaya başlamışlardır (Direk, 2010, s. 19).

Geçimlik tarım evresinde, insanlar çeşitli bitkiler yetiştirerek kendi geçimlerini sağlamışlardır. Bir kısmını tüketirken, diğerlerini depolamak veya takas etmek için kullanarak ilkel ekonomik faaliyetlerin ortaya çıkmasının temelleri atılmıştır. Uzmanlaşmış tarım aşamasında ise, çiftçiler belirli ürünler üzerinde uzmanlaşma eğilimi sağlamışlardır. Bitkisel ürünlerde, meyve ve sebzecilik gibi ana tarım branşları ortaya çıkmıştır. Bu aşamada, çiftçiler belirli bir ürün çeşidini yetiştirebilirken, diğer tarım faaliyetlerini de sürdürebilmektedirler (Direk, 2010, s. 20).

1.1.2. Türkiye’de Tarım Sektörünün Gelişimi

Türkiye, çeşitli medeniyetlere ev sahipliği yapmış ve bu medeniyetlerin etkisiyle zengin bir kültür ve tarih birikimine sahip bir ülkedir. Çeşitli bölgelerdeki iklim farklılıkları, tarımsal faaliyetlerin değişik şekillerde gerçekleştirilmesine olanak sağlamıştır. Türkiye'nin stratejik konumu ve tarih boyunca bir dünya ticaret merkezi olarak öne çıkması, ülkenin farklı alanlarda ve çeşitli yönlerden önem kazanmasını sağlamıştır. Asur, Hitit, Bizans, Selçuklu ve Osmanlı medeniyetleri, Türkiye'nin tarihsel gelişiminde ve kültürel mirasında önemli bir yere sahiptir (Yavuz, 2005).

Cumhuriyet döneminde ekonomik gelişmelerin tarım sektörü üzerindeki etkisi, sanayileşme ve kentleşme politikalarının öncelik kazanmasıyla birlikte değişime uğramıştır. Türkiye'nin milli gelirinde sanayi sektörünün payı artarken, tarım sektörünün ekonomiye sağladığı istihdam, dış ticaret katkısı ve hizmet sektörü üzerindeki etkisi önemini korumaya devam etmiştir. Tarım sektörü, ekonomik sistemde hala önemli bir rol oynamaktadır; ancak sanayi sektörüne yapılan yatırımların artması ve endüstrinin gelişmesi, Cumhuriyet sonrası dönemde ülkenin ekonomik büyüme ve kalkınmasında belirleyici bir faktör olmuştur.

1926 yılında kabul edilen 743 sayılı Medeni Kanun ile çiftçilere toprak sahibi olma hakkı tanınmıştır. Bu yasal düzenleme, çiftçilerin ekonomik faaliyetlerini geliştirebilmeleri için önemli bir adım olmuştur. Çiftçilerin pazara erişimlerini kolaylaştırmak amacıyla örgütlenme çabaları hızlanmış ve bu doğrultuda 1936 yılında Tarım Satış Kooperatifleri ve Birlikleri, 1938 yılında ise Toprak Mahsulleri Ofisi kurulmuştur. 1945 yılında yürürlüğe giren Çiftçiyi Topraklandırma Kanunu ile geçim sıkıntısı çeken çiftçilere arazi tahsis edilmesinin yanı sıra

sermaye, demirbaş ve teçhizat desteği sağlanmıştır. Bu düzenlemeler, çiftçilerin üretim faaliyetlerini sürdürülebilir kılmak ve yeterli gelire ulaşmalarını temin etmek amacıyla gerçekleştirilmiştir (Doğan vd., 2015, s. 33).

1962-1976 yılları arasında Türkiye'de tarım sektörü, ekonomik kalkınma stratejileri kapsamında önemli bir yere sahip olmuştur. Bu dönemde, ithal ikamesine dayalı sanayileşme politikalarının yanı sıra tarımsal üretimi artırmaya yönelik çeşitli düzenlemeler yapılmıştır. Devlet, tarımsal destekleme politikaları aracılığıyla çiftçilerin üretim maliyetlerini düşürmeyi ve tarımsal ürünlerin pazara erişimini kolaylaştırmayı hedeflemiştir. Tarım Satış Kooperatifleri, Toprak Mahsul Ofisi, Tekel, Şeker Şirketi ve ÇAYKUR gibi kamu kuruluşları, tarım sektöründe hem üretimin planlanmasında hem de ürünlerin pazarlanmasında aktif bir rol oynamıştır. Ayrıca, kırsal kalkınmayı desteklemek amacıyla sübvansiyonlar artırılmış ve tarım sektörüne yönelik teşvikler yaygınlaştırılmıştır. Bu politikalar, tarımsal üretimde önemli bir artış sağlarken, kırsal kesimdeki ekonomik faaliyetlerin çeşitlenmesine ve refah düzeyinin yükselmesine katkıda bulunmuştur.

Türkiye'de 1960 yılından sonra uygulanan ekonomi politikaları, ekonomik gelişimin planlı bir şekilde gerçekleştirilmesini sağlamak amacıyla hayata geçirilmiştir. Bu politikalar, ekonominin bilimselleştirilmesi ve hedeflere ulaşmak için yöntemlerin istikrarlı bir şekilde belirlenmesi üzerine odaklanmıştır. Bu amaçla 1960 yılında Başbakanlığa bağlı Devlet Planlama Teşkilatı kurulmuş ve bu teşkilat; ekonomik politikaların oluşturulması ve uygulanmasında etkin bir rol oynamıştır (Özdemir, 2014).

1973-1977 yıllarını kapsayan Üçüncü Kalkınma Programı, sanayileşme yoluyla kalkınma ilkesini temel almıştır. Bu ilke, tarımsal uygulamalara da yansımıştır. Plan çerçevesinde, teknolojinin geliştirilmesi, modern tarım yöntemlerinin yaygınlaştırılması, yeni pazarlar ve kooperatiflerin geliştirilmesi gibi adımlar atılmıştır. Tarımda daha verimli ve etkili yöntemlerin kullanılması ve tarımsal üretimin artırılması hedeflenmiştir. Aynı zamanda, tarım ürünlerinin pazarlanması için yeni pazarlar bulunmuş ve kooperatiflerin kurulması teşvik edilmiştir. Bu programla birlikte, Türkiye'nin sanayileşme süreci hızlandırılmış ve tarım sektörü de geliştirilmeye çalışılmıştır.

1980 sonrasında Türkiye'nin tarım politikalarında önemli değişiklikler yapılmıştır. Bu değişiklikler, dünyada tarımsal yapı ve politikalar üzerindeki dönüşümlerin Türkiye üzerindeki etkisini de yansıtmaktadır. 1980 sonrasında dünyada tarım politikalarında önemli değişimler yaşanmıştır. Neo-liberal politikaların etkisiyle devletin tarım sektöründeki rolü azalmış, sübvansiyonlar ve destekleme alımları azaltılarak piyasa mekanizmalarının önemi artırılmıştır. Ayrıca, küreselleşmenin hızlanmasıyla tarım ürünlerinin uluslararası ticareti artmış ve Dünya

Ticaret Örgütü gibi uluslararası kuruluşlar, tarım politikalarında serbest ticareti teşvik eden düzenlemeler getirmiştir. Bunun yanında, teknolojik yeniliklerin etkisiyle tarımda mekanizasyon, biyoteknoloji ve yüksek verimli üretim teknikleri yaygınlaşmıştır. Tarım politikalarındaki değişimlerde özellikle dış dinamikler, yani uluslararası kuruluşlar etkili olmuştur. Dünya Bankası, Avrupa Birliği, Uluslararası Para Fonu ve Dünya Ticaret Örgütü gibi kuruluşlar, Türkiye'nin tarım politikalarının oluşturulmasında etkin olmuştur. 1980'lere kadar tarım sektörü, Türkiye ekonomisinde önemli bir yer tutmaktaydı. Ancak 1980'lerden sonra uygulanan serbestleşme ve deregülasyon politikaları kapsamında, devletin tarım sektöründeki müdahaleci ve destekleyici rolü azalmış, bu da tarıma ayrılan payın düşmesine neden olmuştur. Bu süreçte, Dünya Ticaret Örgütü (WTO) ve diğer uluslararası kuruluşlar tarafından belirlenen tarım anlaşmaları ve yükümlülükler de etkili olmuştur (Narin, 2011). Bu politikaların sonucunda, tarım sektörünün Türkiye ekonomisindeki payı göreceli olarak azalmış ve diğer sektörlerle kaynak aktarımı hızlanmıştır. Ancak, tarımsal üretimdeki miktar artışına rağmen, çiftçilerin gelir düzeyinde düşüşler gözlenmiş ve tarımsal faaliyetlerden elde edilen refah sınırlı kalmıştır.

1980 sonrasında Türkiye'de yaşanan ekonomik küçülme ve çeşitli sektörlerden çekilme politikaları, tarım sektörünü önemli ölçüde etkilemiştir. Devletin ve kamuya ait şirketlerin piyasadan çekilmesi, özelleştirme politikalarının uygulanmasına yol açmıştır. Bu süreçte çok uluslu şirketler de Türkiye pazarına girmiştir. Özelleştirme ve yabancı şirketlerin gelişi, tarım sektöründe yapısal değişiklikleri beraberinde getirmiştir. Özellikle tarımın endüstrileşmesi ve büyük çiftliklerin artmasıyla, küçük üreticilerin rekabet güçleri azalmış ve gelir düzeylerinin düşmesine neden olmuştur. Ayrıca, tarımın modernizasyonu ve teknolojik yeniliklerin yaygınlaşması da bu süreçte gerçekleşmiştir. Sonuç olarak, devletin tarım sektöründeki rolünün azalması, özelleştirme politikaları ve yabancı şirketlerin gelişi, tarımsal yapıda ve üretim süreçlerinde önemli değişikliklere neden olmuştur (Özertan, 2013).

2000'li yıllar, Türkiye'de ekonomik politikaların küresel trendler ve uluslararası kuruluşlarla yapılan iş birliği çerçevesinde yeniden şekillendiği bir dönem olmuştur. Bu dönemde, ekonomik reformlar kapsamında piyasa mekanizmalarının güçlendirilmesi ve devletin ekonomideki rolünün azaltılması hedeflenmiştir. Tarım sektörü de bu değişimlerden etkilenmiş ve uluslararası kuruluşların yönlendirdiği destek politikaları ile özelleştirme uygulamaları ön plana çıkmıştır. Türkiye'nin kalkınma politikalarında bu yeni yaklaşım, tarımsal yapıyı dönüştürme amacı taşımıştır.

2000'li yıllardan itibaren Türkiye'nin kalkınma politikaları, Uluslararası Para Fonu (IMF) ile yapılan anlaşmalar çerçevesinde şekillendirilmiştir. Bu süreçte, Dünya Bankası

tarafından önerilen küçük ölçekli Doğrudan Gelir Desteği Sistemi gibi destek politikaları uygulanmış ve genel ekonomik desteğin sınırlı olduğu bölgelerde bu tür önlemler hayata geçirilmiştir. Aynı dönemde, Tarım Donatım Kurumu, İstanbul Gübre Sanayi A.Ş., Türkiye Gübre Sanayi A.Ş., Türkiye Şeker Fabrikaları A.Ş., ÇAYKUR ve Tekel gibi kamuya ait kurumsal yapılar özelleştirilmiştir. Bu özelleştirme uygulamalarının temel amacı, ekonomik kalkınmayı teşvik etmek, tarım sektöründe verimliliği artırmak ve devletin ekonomik müdahalelerini azaltarak piyasa mekanizmalarını güçlendirmektir (Narin, 2011).

1.2. TARIM SEKTÖRÜ VE ÖNEMİ

Tarım, toprak ile tohumu buluşturarak bitkisel ürünlerin yetiştirilmesi ve aynı zamanda hayvansal üretim faaliyetlerinin gerçekleştirilmesini kapsayan stratejik bir ekonomik sektördür. Tarım, insanların hayvansal ve bitkisel ürünlere erişimini sağlayarak temel beslenme ihtiyaçlarını karşılamaktadır. Günümüzde tarım sektörü hem gelişmiş hem de gelişmekte olan ülkeler için sürdürülebilir gıda üretimi ve ekonomik kalkınma açısından hayati bir öneme sahiptir. Küresel ölçekte nüfus artışı, kentleşme, iklim değişikliği ve doğal kaynakların tükenme tehlikesi tarım sektörüne olan talebi ve baskıyı artırmaktadır. Bunun yanında, teknolojik yeniliklerin tarımsal üretime entegrasyonu, organik gıdalara olan ilginin artması ve genetiği değiştirilmiş ürünlerin kullanımına ilişkin tartışmalar, tarım sektörünün gelecekteki yönelimlerini belirlemektedir. Bu dinamikler göz önünde bulundurulduğunda, tarımın hem ekonomik hem de sosyal açıdan kritik bir alan olmaya devam edeceği öngörülmektedir.

Açlığın giderilmesinin en güçlü insan dürtüsü olduğu ve bir toplumun en acil sorununun beslenme olduğu bilinmektedir. Güvenlik, sağlık, eğitim, kültür ve rekreasyon gibi ihtiyaçların, beslenme ihtiyacının çözülmesinden sonra önem arz etmektedir. Her ülkenin, sosyal yapısı ve ekonomik gelişmişlik düzeyine göre tarımla uğraşması gerekmektedir. Beslenmenin yaşamın devamı için gerekli olduğundan dolayı tarım sektörü stratejik bir konuma sahiptir. Bu doğrultuda, tarım sektörü gerektiğinde devlet tarafından büyük miktarlarda kaynak ayrılarak desteklenebilmektedir (Acar, 2003).

Nüfusun yaşamını sürdürebilmesi için beslenme sorunu, gıda ürünleri ithalatıyla çözülebilir gibi görünse de bu durum, ülkeleri dışa bağımlı hale getirme riski taşımaktadır. Gıda güvenliğini sağlamak ve tarımsal üretimde bağımsızlığı korumak, ülkeler için stratejik bir öncelik haline gelmiştir. Özellikle savaş, doğal afetler ve kıtlık gibi olağanüstü durumlar, ülkelerin tarımsal stoklarını güçlendirmesini ve üretim kapasitelerini artırmasını zorunlu kılmaktadır. Bu bağlamda, tarım sektörü, kendi kendine yetebilme ve gıda güvenliğini garanti altına alma ihtiyacını karşılamak için kritik bir rol oynamaktadır.

Ülkelerin, tarımsal üretimde dışa bağımlılığı azaltmak ve yerli üretimi teşvik etmek amacıyla kapsamlı tarım politikaları geliştirmesi gerekmektedir. Bu politikalar kapsamında, üretim verimliliğinin artırılması, yenilikçi teknolojilerin tarım sektörüne entegrasyonu, yerel üreticilere finansal ve teknik destek sağlanması, tarım arazilerinin etkin kullanımı ve ürün çeşitliliğinin artırılması öncelikli olmalıdır. Böylece, yerli üretim güçlenecek, gıda güvenliği sağlanacak ve dışa bağımlılık minimize edilecektir (Acar, 2003). Bu politikaların uygulanmasının önemi, tarımsal üretimin doğrudan doğal ve ekonomik koşullardan etkilenmesiyle daha da belirgin hale gelmektedir. Tarımsal üretimin doğal ve iklimsel koşullardan etkilenmesi, tarımsal ürünlerin fiyatlarında istikrarsızlığa neden olmakta ve bu da tarımsal gelirlerde dalgalanmalara yol açarak tarımsal üreticilerin adil ve yeterli bir yaşam standardını sağlamasını zorlaştırmaktadır. Özellikle gelişmekte olan ülkelerde tarımsal altyapının yetersiz olduğu durumlarda tarım riskli bir faaliyet alanı haline gelmektedir. Fiyat dalgalanmaları, çiftçileri ve işçileri belirsizlik ortamına sürükleyebilmektedir (Oya, 2007).

1.2.1. Tarım Sektörünün Ekonomiye Katkısı

Tarım sektörü, ekonomik kalkınmaya diğer sektörler kadar katkıda bulunmamaktadır. Ancak, tarım sektörünün ekonomik kalkınmaya olan etkisi, birçok faktörün bir araya gelmesiyle belirlenmektedir. Gelişmişlik düzeyi, kurumsal kalite, tarımsal iklim faktörleri, tarım dışı geleneksel faaliyetlerin ağırlığı ve pazara erişilebilirlik gibi ekonomik koşullar, politikalar ve kalkınma modelleri bu etkiyi şekillendiren temel unsurlar arasında yer almaktadır. Bununla birlikte, modernizasyon veya sanayileşme sürecindeki değişimlerin yanı sıra uluslararası pazarlara giriş için farklı yöntemlerin ve diğer faktörlerin de bu süreç üzerinde oldukça etkili olduğu görülmektedir (Pinilla & Willebald, 2018).

Bu durum, düşük gelirli ülkelerde tarım sektörünün milli gelire sağladığı katkının büyüklüğü ile daha açık bir şekilde gözlemlenmektedir. Özellikle bu ülkelerde tarım sektöründe çalışan nüfusun yoğunluğu dikkat çekmektedir. Ancak, tarımın ekonomik kalkınmaya olan katkısı, ülkeden ülkeye farklılık göstermekte ve zaman içinde değişiklik arz etmektedir (Ardeni & Freebairn, 2002).

21. yüzyılda dünya genelinde çevre, enerji ve finansal krizler artış göstermiş, bu durum risk yönetimi ve yönetişimin önemini artırmıştır. Aynı dönemde, kaynakların etkin kullanımı yaygınlaşırken, tarımsal alanların daralması, enerji ve su kullanımının artışı, doğal kaynakların ise giderek tükenmesi dikkat çekmektedir. Türkiye'de ise tarım sektörünün ve istihdamdaki payının son yıllarda azaldığı gözlemlenmektedir. Bununla birlikte, organik tarım, helal üretim, iyi tarım uygulamaları, döngüsel ekonomi, biyoteknoloji, bölgesel ve serbest ticaret

anlařmaları, ekonomi ve akıllı tarım gibi yaklařımların mevcut sorunlara çözümler sunması ve sektöre önemli katkılar sağlanması beklenmektedir (Çak & Yavuz, 2023).

Tarım sektörünün, yalnızca gıda güvenliğini sağlama açısından deęil, aynı zamanda ekonomik büyüme, istihdam yaratma ve kırsal kalkınmayı destekleme gibi birçok alanda önemli katkılar sunduęu bir gerçektir. Bu nedenle, sektörün ekonomi üzerindeki etkilerinin detaylı bir şekilde ele alınması faydalı olacaktır. Tarım sektörü, bir ülkenin ekonomik kalkınmasında ve sürdürülebilir büyüme sağlamasında kritik bir rol oynamaktadır. Gıda güvenliğinin yanı sıra, tarımın döviz girdisi, ticaret dengesi ve üretim faktörleri üzerindeki etkileri, sektörün ekonomik katkılarının çok yönlülüęünü ortaya koymaktadır. Bu katkılar ařaęıda sıralanmıřtır.

1. Tarımsal Ürün Katkısı: Tarımsal üretim insanlığın hayatta kalmasını ve gelecekte de varlığını sürdürebilmesi açısından önemlidir. Bu üretim, gıda ihtiyacının sağlanmasında büyük bir rol oynayarak ekonomik kalkınmaya katkıda bulunmaktadır (Dinler, 2000). Açlık, hayatta kalma mücadelesiyle doğrudan ilişkilidir ve kendini besleme ihtiyacının karşılanması insanlık için en önemli faktördür. Bu yüzden bir toplumun en acil sorunu, nüfusunun hayatta kalmasını sağlamaktır. Beslenme, yařamın devamı için elzemdir ve gıda maddelerini üreten tarım sektörü stratejik bir öneme sahiptir. Bu nedenle, tarım sektörünün desteklenmesi için büyük miktarlarda kaynak aktarılmalıdır. Günümüzde hem gelişmiş hem de gelişmekte olan ülkelerin kendi kendine yetme konusunda politikalar geliřtirmektedir. Tarımsal destek programları da bu ülkelerde tarımsal üretimin ve gıda güvenliğinin sağlanması amacıyla önemli bir rol oynamaktadır. Tarımsal üretimin kendi kendine yeterlilik ve gıda güvenliği açısından önemli olduęu, özellikle olaęanüstü durumlarda zorluklarla karşılaşmamak adına önlemler alınması gerekmektedir (Acar, 2006).

2. Pazar Katkısı: Gelişmekte olan ülkelerin tarımda modernleşmesi ve altyapı yatırımlarının artması, tarımın ekonomik kalkınmaya olan katkısını artırmaktadır. Düşük tarımsal fiyatlar, sanayi sektörünün hammadde ve gıda ürünlerini daha ucuz temin etmesini sağlamak ve böylece sanayinin karlılığını artırmaktadır. Ancak bu durum tarım sektörünün alım gücünü düşürdüęünde, sanayi sektörünün ürünlerine olan talepte azalma olmaktadır. Bu nedenle, sektörler arasında dengeli bir büyüme sağlamak için ticaret dengesinin korunması gerekmektedir. Hem sanayi sektörünün büyümesi hem de tarımsal fiyatların dengeli bir seviyede tutulması önemlidir. Böylece her iki sektör de maksimum düzeyde büyüyebilecektir. Bu nedenle, ekonomik büyüme için dengeli ticaret ilişkilerinin belirlenmesi gerekmektedir (Thirlwall, 2003).

3. Üretim Faktörü Katkısı: Tarım sektörü, ekonomik kalkınma sürecinde üretim faktörleri üzerinde önemli bir etkiye sahiptir. Tarım sektörü, sanayi sektörüne hammadde sağlamak gibi önemli bir konumda yer almaktadır. Tarım, diğer sektörler üzerinde de etkili olmasına rağmen en büyük etkiyi üretim faktörleri üzerinde yapmaktadır. Özellikle emek faktörü üzerinde belirgin bir etkisi bulunmaktadır. Tarım sektörü işgücü fazlası yaratır ve bu fazla işgücü diğer sektörlerle yönlendirilmektedir. Örneğin, Orta Çağ'da tarım sektöründeki işgücü fazlasının şehirlere göç etmesi, ticaret ve sanayinin gelişmesi için ucuz işgücü sağlanmasına neden olmuştur. Tarım sektörünün diğer etkileri ise sermaye ve hammadde sağlamasıdır. Tarım sektörü ayrıca, sanayi sektörünün gelişmesi için önemli bir sermaye kaynağı sağlamaktadır. Bu sermaye genellikle tarım tasarruflarından gelmektedir. Tarım işletmeleri, tarımsal faaliyetlerden elde ettikleri geliri sanayi sektörüne aktarmaktadır. Devlet, tarımsal üretim fazlasını vergilendirme veya el koyma yoluyla sermaye birikimi sağlamaktadır. Bu yöntem, devletin tarıma yatırım yapmak veya diğer alanlarda kullanmak için tasarruf etmesine olanak sağlamaktadır (Doğan, 2009).

Bugün, insanların gıda ihtiyaçlarını karşılamak için tarım arazisi kullanımı konusunda büyük sorunlar yaşanmaktadır. Hem ormanların hem de meraların tarım arazisi olarak kullanılması ve sulanan alanların artması, tarım için uygun arazi bulma konusunu zorlaştırmıştır. Tarım arazisi varlıklarını genişletme olasılığı sınırlıdır ve mevcut arazilerde tarım yapmak, insanları beslemek için yeterli olabilirken, gelecekteki artan dünya nüfusunu karşılamak için tarımda verimlilik ve kalite artışı gerekmektedir. Bu zorluklara karşın, tarım arazisi kullanımında verimlilik ve kalite artışı sağlanarak, insanların beslenme ihtiyaçlarının karşılanması için çözümler bulması gerekmektedir (Boz, 2004).

4. Döviz Katkısı: Tarım sektörünün Türkiye ekonomisinde dış ticaret üzerinde büyük bir etkisi bulunmaktadır. Türkiye, tarım ürünlerinin ihracatından önemli miktarda gelir elde eden bir ülke konumundadır. Tarım sektörü, ülkeler için olumlu bir etkiye sahip olmakla beraber ekonomik kalkınma ve döviz girdisi sağlama açısından önemli bir sektördür. Döviz girdisi, tarım ürünlerinin ihraç edilmesiyle elde edilmektedir. Ayrıca, tarım yoluyla döviz girdisi sağlamak için ithal edilecek ürünlerin yerli üretimi teşvik edilmektedir. Bu da dövizin ülke dışına çıkmasını önlemektedir. Son olarak, tarıma dayalı sanayileşme ve hammadde ihracatı da döviz girdisi sağlama konusunda önemli bir rol oynamaktadır (Deran, 2005).

Gelişmekte olan ülkeler tarım ürünleri ihraç ederek döviz kazanma konusunda zorluklarla karşılaşabilmektedirler. Benzer tarımsal ürünleri ihraç eden ülkelerin sayısının artması, uluslararası tarım ürünlerinin fiyatlarının düşmesine neden olmaktadır. Bu durum, tarım ürünlerinin gelir ve fiyat elastikiyetlerinin azalmasına neden olmaktadır. Sonuç olarak, ihracat gelirleri düşer ve bu durum ülke ekonomisine olumsuz etki sağlamaktadır. Bu

zorlukların üstesinden gelmek için çözüm olarak, ihracat ürünlerinin çeşitlendirilmesi ve işlenmesi önem arz etmektedir (Parasız, 2005, s. 128).


1.3. TARIM SEKTÖRÜNÜN TÜRKİYE EKONOMİSİNDEKİ YERİ VE ÖNEMİ

Türkiye'deki istihdamın sektörel yapısı incelendiğinde, tarım sektörünün Cumhuriyet'in kuruluşundan 1999 yılına kadar toplam istihdamda en yüksek paya sahip olduğu görülmektedir. Ancak, yıllar içinde sosyal, ekonomik ve toplumsal değişimlerin etkisiyle hizmet ve sanayi sektörlerinin istihdam içindeki payı artarken, tarım sektörünün payı azalmıştır. Bu düşüşün ana nedenleri tarım sektöründeki makineleşmeyle işgücü talebinin azalması, kırsal alanlarda nüfusun azalmasıyla birlikte sanayi ve hizmet sektörlerindeki işgücü ihtiyacının artması ve ekilebilir arazilerin parçalanması olarak gösterilebilir. Bu nedenler sonucunda tarımsal istihdam genel olarak azalmıştır (Kalkınma Bakanlığı, 2012; OECD, 2011).

2000 ve 2001 yıllarında Türkiye'de yaşanan ekonomik krizlerin ardından, Uluslararası Para Fonu (IMF) ile yapılan bir anlaşma çerçevesinde tarım sektörüyle ilgili önemli düzenlemeler kabul edilmiştir. Bu düzenlemeler kapsamında, mevcut tarımsal sübvansiyonların kaldırılarak yerine Doğrudan Gelir Desteği (DGD) sistemiyle destek sağlanması, destek alım fiyatlarının dünya fiyatları baz alınarak belirlenmesi, Çay İşletmeleri Genel Müdürlüğü (ÇAYKUR), Türkiye Tekel Genel Müdürlüğü (TEKEL) ve Şeker Fabrikalarının özelleştirilmesi gibi adımlar atılmıştır. Ayrıca, Tütün ve Şeker Kanununun yürürlükten kaldırılması ve Türkiye Cumhuriyeti Ziraat Bankası tarafından verilen sübvansiyonlu kredilerin sona erdirilmesi de bu düzenlemeler arasında yer almıştır. Bu kapsamlı reformların hayata geçirilebilmesi için, 2001 yılında Türkiye Hükümeti ve Dünya Bankası arasında Tarım Reformu Uygulama Projesi (TRUP) ya da İngilizce adıyla Agricultural Reform Implementation Project (ARIP) başlatılmıştır (Hatunoğlu & Eldeniz, 2012).

Tarım sektörüyle ilgili olarak çok boyutlu bir değerlendirme yapılması gerekmektedir. Sektörün etkisi sadece ekonomik boyutla sınırlı kalmamakta, aynı zamanda gıda güvenliği, çevre, doğal kaynaklar, enerji, yoksulluk ve kırsal kalkınma politikaları gibi birçok alana da yansımaktadır. Bu nedenle, tarım sektörü politikalarının uygulanması öncesinde sektörle ilgili konuların detaylı bir şekilde analiz edilmesi gerekmektedir. Ayrıca, tarım sektörünün diğer sektörlerle karşılaştırıldığında ekonomiye katkısının yetersiz olduğunun kabul edilmesi ve bu sektörde yapısal değişime ihtiyaç duyulduğunun farkında olunması gerekmektedir. Bu çerçevede, tarım sektörünün stratejik hedefleri analiz edilerek, gelişmiş ve gelişmekte olan diğer ülkelerle kıyaslanması önem arz etmektedir (Özertan, 2013).

Tarımsal nüfustaki azalmanın ana sebeplerinden birisi kırsaldan kente yaşanan göçün artmasıdır. 1950'lerde, traktörlerin ülkeye girmesiyle tarım sektöründe işsiz kalan insanlar şehirlerde iş bulmak için göç etmeye başlamıştır. Ancak, 1960'lı yıllarda kırsal nüfus oranı hala kentsel nüfus oranından yüksek oranlara sahiptir. Fakat son yıllarda bu oran hızla azalmıştır. 2019 yılı itibariyle kırsal nüfus oranı ciddi derecede gerilemiştir. Bu düşüşün nedeni, özellikle 1980'lerden sonra tarım sektörü için devlet desteğinin azalması ve gelir düzeyinin düşmesi insanları kentte yaşamaya yöneltmiştir. Üretim maliyetlerinin sürekli artması, devletin eskiden sağladığı sübvansiyonları ve düşük faizli kredileri sunmaması bu göçü hızlandırmıştır. Özel sektör ve yabancı şirketlerin devreye girmesiyle küçük çiftçiler rekabet edemez hale gelmiş ve borçlarından kurtulmak için topraklarını satmak zorunda kalmıştır (Bingöl & Meçik, 2021).




Şekil 1: Türkiye’de Kentsel ve Kırsal Nüfus Değişimi (%) (TÜİK, 2022a.)

Şekil 1’de, Türkiye’deki kırsal ve kentsel nüfus oranlarının yıllara göre değişimi sunulmaktadır. Verilere göre, 1940’lardan itibaren kırsal nüfus oranı sürekli bir azalma eğilimi göstermiş, buna karşılık kentsel nüfus oranı düzenli bir artış sergilemiştir. 1940’lı yıllarda kırsal nüfus, toplam nüfusun büyük bir bölümünü oluştururken, kentsel nüfus oldukça düşük oranlarda kalmıştır. 1980’lere kadar kırsal nüfusun oranındaki azalma ve kentsel nüfustaki artış eğilimi devam etmiştir. Özellikle 1980’den sonra kentsel nüfus oranında belirgin bir hızlanma yaşanmış ve 2000’lerden itibaren kentsel nüfus oranı, kırsal nüfus oranını geçmiştir. 2020 yılı ve sonrasına gelindiğinde, kentsel nüfus oranı %80’e ulaşmış, kırsal nüfus oranı ise %20’nin altına düşmüştür. Bu değişim, ekonomik gelişmeler, sanayileşme süreçleri ve kentlerdeki iş olanaklarının artışı gibi faktörlerle açıklanabilmektedir.


Türkiye’nin istihdam yapısı incelendiğinde, tarım sektörünün her zaman önemli olduğu görülmektedir. Ancak, sanayinin ve istihdam olanaklarının artmasıyla birlikte tarımsal istihdam hızla azalmıştır. Bunun sebebi, kırsaldan kente yaşanan göçün artmasıdır. Ayrıca, tarımsal istihdamda yaş ortalamasının yüksek olması da gelecekte sorun yaratacağı tahmin edilmektedir.

Bu sorunun çözümü için, eğitim politikalarının kırsal kesimde yaygınlaştırılması ve sermayenin tarım sektörüne yönlendirilmesi gerekmektedir. Bunun yanı sıra, yüksek kayıt dışı istihdam oranı ve ücretsiz aile işçileri tarım sektörünün en büyük sorunlarından biri olarak karşımıza çıkmaktadır (Turhan & Erdal, 2022).



Şekil 2: Ekonomik Yönden Aktif Nüfusun Sektörel Dağılışı (%) (TÜİK, 2022b.)

Şekil 2'de, Türkiye'deki ekonomik sektörlerin yıllara göre yüzdelik dağılımı gösterilmektedir. Tarım sektörü 1970'ten 2022'ye kadar sürekli bir düşüş göstermiştir. 1970'te %67,7 olan tarım sektörü nüfusu, 2022'de %16'ya kadar gerilemiştir. Sanayi sektörü genel olarak istikrarlı bir artış sergilemiştir. 2000'de bir sıçrama yaşanmış, 2022'de %21,8'e ulaşmıştır. İnşaat sektörü 2005'ten itibaren kaydedilmeye başlanmış olup %5-%7 aralığında bir dalgalanma göstermektedir. Hizmet sektörü yıllar içinde istikrarlı bir şekilde artmıştır. 1970'te %20,2 olan hizmetler sektörü, 2022'de %56,3'e yükselmiştir. Bu grafiğe göre, Türkiye ekonomisinin yıllar içinde tarımdan hizmet ve sanayi sektörlerine doğru kaydığını göstermektedir.



Şekil 3: Türkiye'de işsizlik oranı (%) (TÜİK, 2022c.)

Şekil 3'te sunulan verilere göre, Türkiye'deki işsizlik oranı 2020 yılında %12,9 ile en yüksek seviyesine ulaşmış, 2022 yılı itibarıyla %10,1 seviyesine gerilemiştir. Bu düşüş,

COVID-19 pandemisi sonrası ekonomik toparlanmanın işgücü piyasasına yansımaları göstermektedir. Tarım dışı işsizlik oranı ise 2020 yılında %15,3 ile zirve yapmış, takip eden yıllarda kademeli bir azalma sergilemiştir. Genel olarak, Türkiye'nin işgücü piyasasında artan işgücüne katılım ve istihdam artışı gözlemlenmekle birlikte, dönemsel ekonomik krizler işsizlik oranlarında belirgin dalgalanmalara yol açmıştır.

Tarım sektörünün işgücü piyasasındaki rolü bu bağlamda dikkat çekicidir. Özellikle kriz dönemlerinde tarım sektörü, düşük vasıflı işgücü için bir geçici istihdam kaynağı olarak işlev görmüştür. Bununla birlikte, tarım sektöründeki istihdam payının zamanla azalması, kentleşme, sanayileşme ve hizmet sektörünün büyümesi gibi yapısal dönüşümlerle ilişkilidir. Bu durum, işgücü piyasasında tarım dışı sektörlerdeki istihdam dinamiklerini ön plana çıkarmış ve işsizlik oranlarındaki dalgalanmaları daha belirgin hale getirmiştir. Özellikle genç işsizliği gibi yapısal sorunlar, tarım dışı sektörlerde yeterli istihdam yaratılmaması durumunda derinleşmektedir. Bu çerçevede, tarım sektörünün işgücü piyasasındaki stratejik önemi, ekonomik krizlerin etkilerinin hafifletilmesi ve istihdamın sürdürülebilir kılınması açısından yeniden değerlendirilmelidir. Tarım dışı sektörlerdeki istihdam yaratma kapasitesinin artırılması, işgücü piyasasının krizlere karşı dayanıklılığını güçlendirmek için kritik bir gereklilik olarak ortaya çıkmaktadır.


1.3.1. Tarımın GSYH'deki Yeri ve Önemi

Tarım sektörü başta sanayi sektörü olmak üzere birçok sektöre hammadde olanağı sağlamaktadır. 19. yüzyıla kadar, sanayi devriminin henüz gerçekleşmediği bir dönemde, tarım sektörü tüm ülkeler için temel gelir kaynağı konumundaydı. Bu dönemde tarım sektörü, Gayri Safi Yurt İçi Hasıla (GSYİH) içerisindeki en yüksek paya sahipti ve hatta bazı ülkelerde yurtiçi hasılanın tamamını oluşturuyordu. Ancak, sanayi devrimi ve sonrasındaki süreçte sanayi ve hizmet sektörlerinin hızla gelişmesiyle birlikte, tarım sektörünün GSYİH içindeki payı azalmaya başlamıştır (Sahin, 2014, s. 257). Özellikle sanayi sektöründeki teknolojik ilerlemeler, üretim süreçlerinin çeşitlenmesi ve hizmet sektörünün genişlemesi, ekonomik yapının tarımdan sanayi ve hizmet ağırlıklı bir yapıya dönüşmesine neden olmuştur. Bu dönüşüm, ekonomik büyüme ve gelişme süreçlerinin doğal bir sonucu olarak değerlendirilmektedir. Tarım sektörünün GSYİH'ye katkısının tarihsel olarak daha yüksek olması, dönemin ekonomik koşullarını yansıtmaktadır; ancak sanayileşme ile bu katkı azalmış ve sektörler arasındaki denge değişmiştir.

2010 ve 2016 yılları arasında tarım sektöründe istihdam kayıpları yaşanmıştır. Bu dönemde tarım sektöründe yaklaşık 683 bin kişi işten çıkarılmış ve bu kişiler diğer sektörlerle kaymıştır. Tarım sektörü ve imalat sektöründe %7'ye varan bir düşüş yaşanmıştır. İmalat

sektöründeki istihdam artışı, tarım sektöründeki iş gücüne de pozitif etki sağlamıştır. Tarım sektörünün istihdama ve dolayısıyla GSYİH'ye etkisi büyüktür. Ancak tarım sektörünün gelirlerinin istikrarlı olmaması fiyat dalgalanmalarının yaşanması, üretici gelirlerini olumsuz etkilemektedir (TÜSİAD, 2022).

Tarımın milli gelir içindeki payı da tarım sektörü için oldukça önemlidir. Cumhuriyetin ilk yıllarında tarım sektörü, GSMH içinde önemli bir paya sahipti. Ancak zaman içinde bu oran değişmiştir. 1925-1929 döneminde tarım sektörünün GSMH içindeki payı %47 iken, 1933-1938 döneminde %40'a kadar gerilemiştir (Karluk, 2009). 1990'lı yıllardan bu yana tarım gelirlerinde nominal bir artış yaşanmasına rağmen, tarım sektörünün milli gelir içindeki payı sürekli olarak azalmıştır. 1990 yılında tarımın milli gelir içindeki payı %17,1 iken, 1998 yılında %13,1'e düşmüştür. Bu eğilim 2000'li yıllarda da devam etmiş ve 2011 yılında %7,5'e, 2020 yılında %6,6'ya, 2021 yılında ise %5,8'e gerilemiştir. 2022'nin ilk çeyreğinde ise %2,6 olarak kaydedilmiştir. Tarımsal gelirin milli gelir içindeki azalmasının temel nedeni, tarım dışı sektörlerin büyüme oranının tarım sektörünün büyüme oranından daha yüksek olmasıdır. Tarım sektöründe çalışanların geliri tarım dışı faaliyetlerle uğraşanlardan genellikle daha yüksek olmasına rağmen, tarımsal gelir ülke ortalamasının altında kalmaktadır. Bu durumun en önemli nedeni, tarımsal ürün fiyatlarının düşük olmasıdır (Dinler, 2000, s. 89-93).



Şekil 4: Gayri Safı Yurtiçi Hasıla Büyüme Hızı ve Tarımın Gayri Safı Yurtiçi Hasıla İçindeki Payı (2006- 2021) (TCMB, 2022)

Şekil 4'te Türkiye'nin yıllara göre tarımsal ve genel ekonomik büyüme ile tarım sektörünün ekonomi içindeki payı karşılaştırılmıştır. 2009 yılında negatif bir büyüme hızı görülmektedir, bu da küresel ekonomik krizin etkisiyle ekonominin daraldığını işaret etmektedir. Sonraki yıllarda büyüme genel olarak pozitif seyretmektedir. Tarımın büyüme hızı, 2009 yılında düşük bir büyüme yaşamış, ancak 2010 yılında tarım sektöründe çok ciddi bir büyüme gerçekleşmiştir. Bu hızlı yükseliş, çeşitli faktörlere iyi hasat, iklim koşulları veya

politika etkilerine bağılı olarak gerekleşmiştir. Ancak bu büyüme oranları daha sonraki yıllarda dalgalı bir seyir izlemektedir. Tarım sektörünün toplam ekonomi içindeki payını gösteren bu grafik genel olarak %5 ile %10 arasında deęişmiştir. Yıllar içinde tarım sektörünün payında büyük bir deęişiklik olmadığı, ancak hafif bir azalma trendi olduğu görölmektedir. Bu durum, Türkiye'de sanayi ve hizmetler sektörlerinin tarıma göre daha hızlı büyüdüğünü yansıtmaktadır.

1.3.2. Tarım Sektörünün Dış Ticaretteki Payı ve Önemi

İhracat ve ithalat, ekonomik kalkınma için önemli bir faktördür. Tarım sektörü, gelişmekte olan ölkelerde en büyük ihracat gelirini sağlamaktadır. Ancak tarımsal üretim genellikle kendi ihtiyaçlarını karşılamakla sınırlı kalmakta ve bu da ihracat fırsatları yaratmamaktadır. Bu nedenle devlet, tarımsal ürünlerin ithal edilmesi için borçlanmak zorunda kalmaktadır. Bunun sonucunda ekonomik refahta düşüş yaşanmaktadır. İhracatta başarılı olabilmek için tarım ürünlerinin pazarı genişletilmeli ve gelişmiş ölkelere olan ihracat artırılmalıdır. Ayrıca, tarım sektörünün diğer sektörlerle entegrasyonu sağlanarak hammadde temini ve dövizin sanayiye yönlendirilmesi teşvik edilmelidir. Bu teşvikler hammadde temininin kolaylaşmasını sağlamaktadır (Erbay, 2013).

Türkiye'de tarım sektörü, ihracat ve ithalat üzerinde önemli bir etkiye sahiptir. Ülkenin ihracat gelirinin büyük bir kısmı tarım ürünlerinden elde edilmektedir. Tarım sektörünün ekonomik kalkınma ve döviz girdisi sağlama konusunda olumlu etkisi bulunmaktadır. Bu döviz girişı üç şekilde gerçekleşmektedir: tarımsal ürünlerin ihra edilmesi, ithal edilen ürünlerin yerine yerli üretimin sağlanması ve tarıma dayalı sanayileşme ile hammadde ihracatının sağlanmasıdır. Tarım sektörü, ölkelerin döviz kazanmasına ve ölkedışına çıkan dövizin azalmasına yardımcı olmaktadır. Bu nedenle, tarım sektörünün dış ticaret üzerindeki etkisi ve döviz girdisi sağlama konusunda önemli bir rolü bulunmaktadır (Deran, 2005, s. 29).

Türkiye'nin tarım, gıda ve içecek sektöründe 2022 yılında 26,49 milyar dolar ihracat ve 21,13 milyar dolar ithalat gerçekleşmiştir. Dış ticaret dengesi 5,36 milyar dolar fazla olarak kaydedilmiştir. Büyükbaş hayvan ithalatı ise 2023 yılında 1 milyar 163 milyon dolar tutarında gerçekleşmiş, sığır ithalatı aralık ayında yüzde 683,3 artış göstermiştir. En çok ihra edilen ürünler arasında un, fındık içi ve rafine ayiek yağı bulunurken, en çok ithal edilen ürünler arasında buğday, soya fasulyesi ve ham ayieęi yer almaktadır. 2023 yılında en fazla ihracat Irak, Almanya ve Rusya'ya yapılırken, en fazla ithalat Rusya, Ukrayna ve Brezilya'dan gerçekleşmiştir (TGDF, 2023).

1.3.3. Tarım Sektörünün Sanayiye Katkısı

Türkiye'deki tarıma dayalı sanayi hammadde araştırmaları genellikle tarım ürünlerini kullanmaktadır. Bu durum, bugün tarıma dayalı endüstrilerin büyük bir kısmının ihracata katkıda bulunduğunu göstermektedir. Tarım sektörünün hammadde sağlaması, ekonomik kalkınma üzerinde olumlu bir etkisi bulunmaktadır. Ham madde ithalatının ülke içindeki dövizin başka alanlarda kullanılmasını kısıtlamaktadır. Tarım sektörü, tarıma dayalı sanayilere hammadde sağlaması açısından tarımın sürdürülebilirliği tarımı vazgeçilmez bir sektör haline getirmektedir (Akdeniz, 2019).

Tarım sektörü, sanayi sektöründe hammadde olarak kullanılan tarımsal ürünleri üretirken, sanayi sektörü de tarımsal girdiler olarak adlandırılan tarım ürünlerini kullanmaktadır. Bu şekilde her iki sektör birbirini tamamlamaktadır. Bu ilişki, tarım sektöründeki üretimin sanayi sektöründe işlenmesi ve değer kazanması sayesinde ekonomik büyüme ve kalkınmaya pozitif etki sağlamaktadır (Demirbaş & Tosun, 2005, s. 29).

Tarım sektörü, ekonomik faaliyetlerin sadece kendi alanında gerçekleşmediği önemli sektörlerden biridir. Ekonomik hayat, sosyal hayatın önemli bir parçası olarak istihdam fırsatları yaratırken, çalışanların sosyal yaşamlarını da iyileştirmektedir. Tarım sektörü, ülkelerin ekonomik kalkınmasına da katkıda bulunmaktadır. Özellikle ihracat yoluyla ihraç edilen tarım ürünlerinin artması, ülkeye döviz girişini sağlamaktadır. Bununla birlikte, tarım sadece beslenme açısından değil, diğer sektörlerle hammadde sağlama açısından da stratejik öneme sahiptir. Tarım sektörü, dışa bağımlılığın azaltılmasında önemli bir rol oynamakta ve ekonomideki işlevleri hem ülke içinde hem de uluslararası alanda önemlidir (Erdem & Yücel, 2015, s. 90).

Tarım ürünleri, endüstri için önemli bir hammadde kaynağı durumundadır. Bu nedenle, gelişmiş ülkeler önce tarım sektörünü geliştirerek ekonomik büyümeyi güvence altına almışlardır. Tarımdan elde edilen ekonomik ve hammadde kaynakları, gelişimin temelini oluşturmaktadır. Tarım, sanayileşme süreciyle birlikte önemini koruyan ve ekonomik büyümeye katkı sağlayan bir sektördür (Tuna, 1993).

Tarım sektöründe gelir artışının ülke ekonomisine olumlu bir etkisi olduğu görülmektedir. Ancak bu etkinin artırılabilmesi için, üretilen ürünlerin ihraç edilebilir nitelikte olması gerekmektedir. Aksi takdirde, iç piyasada tarımın istihdama ve ülke ekonomisine katkı sağlayabileceği belirtilse de dış ticaretteki hareketlilik, ülkeye döviz girdisi sağlama açısından öne çıkmaktadır. Tarım ürünlerinin ihracat potansiyelinin artırılması, ülke ekonomisi için önemli bir etki sağlayacaktır (Ege, 2011).

1.4. TÜRKİYE’DE TARIMSAL POLİTİKALAR

Dünya, günümüzde hızla artan nüfusun yarattığı temel ihtiyaç taleplerine yanıt vermekte zorlanmaktadır. Bu durum, özellikle temel besin ürünlerine olan ihtiyacın artmasına ve buna bağlı olarak tarımsal üretimde ciddi sorunların ortaya çıkmasına neden olmuştur. Artan talebe rağmen tarım sektörü, büyük ölçüde iklim koşullarına bağlı olduğu için sürdürülebilir üretim konusunda çeşitli zorluklarla karşılaşmaktadır. Bu sorunların çözümü için, tarım sektöründe yeni yöntemlerin geliştirilmesine ve yenilikçi uygulamaların hayata geçirilmesine yönelik çalışmalar yürütülmektedir. Bu bağlamda, farklı tarım politikalarının benimsenmesi önem kazanmaktadır. Söz konusu politikaların temel amacı, üretim sürekliliğini sağlamak, kaynakları etkin bir şekilde kullanmak ve tarım sektörünün iklim değişikliği gibi dışsal faktörlere karşı dayanıklılığını artırmaktır. Ayrıca, bu politikalar hem yerel hem de küresel ölçekte gıda güvenliğini sağlamak adına stratejik bir rol oynamaktadır. Dolayısıyla, sürdürülebilir bir tarım sistemi oluşturmak için bilimsel ve teknolojik yeniliklerin tarım politikalarına entegre edilmesi gerekmektedir.

Cumhuriyet’in ilk yıllarındaki tarım politikaları, köylülere toprak dağıtılması ve tarımın bilimsel yöntemlerle yapılması gibi hedefler üzerine kurulmuştur. Bu dönemde ziraat enstitüleri kurularak tarım için eğitim ve araştırma faaliyetlerine önem verilmiştir. Ayrıca, banka ve Tarım Kredi Kooperatifleri köylülere kredi sağlamış ve tarımsal satışların artması amaçlanmıştır. Ürünlerin pazarlanması ise kooperatifler, İş Bankası, Ziraat Bankası ve Tekel tarafından desteklenmiştir. Destek faaliyetleri ise İdare ve Toprak Mahsulleri Ofisi gibi kurumlar aracılığıyla yürütülmüştür. Bu sayede çiftçilerin daha iyi koşullarda üretim yapması ve gelirlerini artırması hedeflenmiştir (ZMO, 2021).

Türkiye’de tarım sektörü, liberal ekonomi politikalarının en çok etkisini hisseden sektörlerin başında gelmektedir. Tarım politikaları, Avrupa Birliği, Dünya Bankası ve Dünya Ticaret Örgütü gibi uluslararası kuruluşlar tarafından belirlenmektedir. Ancak bu süreçte özelleştirme ve uluslararası anlaşmaların etkisi altında kalan tarım sektörü, topraksız nüfus, küçük işletmelere sahip nüfus, işsizlik, sigortasız çalışma ve yoksulluk gibi sorunlarla karşı karşıya kalmıştır (Öztürk, 2008).

Planlı dönemde ürün destekleri, girdi destekleri ve düşük faizli krediler gibi çeşitli politikalar geliştirilmiştir. Ancak 2000 yılından sonra Tarım Reformu Uygulama Projesi (ARIP) ile reformlar yapılarak alan bazlı destekler ve kırsal kalkınma politikaları uygulanmıştır. Günümüzde bitkisel üretimde mazot, gübre, toprak analizi destekleri, biyolojik mücadele destekleri, tarımsal danışmanlık gibi politika araçları kullanılmaktadır. Hayvancılıkta ise verimliliği artırmak, gen kaynaklarını korumak ve alternatif gelir kaynakları oluşturmak

hedeflenmektedir. Tarım-sanayi entegrasyonunu sağlamak amacıyla %50 hibe destekli projelerle kırsal kalkınma politikaları uygulanmaktadır. Ayrıca, arazi toplulaştırma ve tarım sigortası destekleriyle tarımsal altyapı güçlendirilmekte ve üretici gelirleri korunmaktadır. Bu politikalar, tarım sektörünü desteklemek ve kırsal kalkınmayı sağlamak amacıyla uygulanmaktadır (Tan vd., 2015).

Tarım sektörünün ekonomik başarısını ve ülkeye olan katkısını artırmak için, çiftçilerin tarım sektöründe elde ettikleri gelirin önemi büyüktür. Tarımla uğraşan çiftçilerin, diğer sektörlerde çalışarak elde edebilecekleri gelire kıyasla daha düşük bir kazançla yetinmeleri, sektörde kalıcılıklarını zorlaştırmaktadır. Bu nedenle, çiftçilerin tarım sektöründe devam etmelerini sağlamak ve başka sektörlerle yönelmelerini önlemek adına, gelir düzeylerinin artırılmasına yönelik politikalar geliştirilmelidir. Aksi takdirde, çiftçilerin tarımdan uzaklaşması ülkenin gıda güvenliği ve kendine yeterlilik durumuna zarar verecek, dışa bağımlılığı artıracak ve cari açığın büyümesine neden olacaktır. Bu bağlamda, tarım sektörünün sürdürülebilirliği için çiftçilerin gelir seviyesini artırmak büyük önem taşımaktadır.

Tarımsal üretimdeki fiyat istikrarı, hem tüketicilere uygun fiyatlarda gıda ürünleri sağlamanın hem de üretici gelirlerinde istikrarın sağlanması açısından önemlidir. Üretim yönelimi, kendi kendine yeterliliği sağlamayı amaçlasa da tarım sektöründe üretim ve fiyat istikrarının sağlanması da önemli hedefler arasında yer almaktadır. Tarımsal üretimin ve ürün arzının istikrarının sağlanması, tarımsal üretimin istikrarına bağlı olup, devlet çeşitli politika araçları kullanarak üretimi istikrara kavuşturmaya çalışmaktadır. Bu amaçla, fiyat istikrarını sağlamaya yönelik stok, ithalat ve ihracat politikaları da uygulanmaktadır. Bu sayede, tarımsal ürünlerde fiyat istikrarı ve dolayısıyla tüketicilere uygun fiyatlar ve üreticilere istikrarlı gelirler sağlanmaya çalışılmaktadır (Çomaktekin, 2009).

Tarım sektöründe verimlilik, sulama, gübreleme, pestisit kullanımı, doğru tohum seçimi, uygun işgücü kullanımı gibi faktörlerin yanı sıra ürünlerin taşınması, depolanması, pazarlaması, girdi fiyatları, ürün fiyatları, vergi uygulamaları, teşvikler, desteklemeler gibi bir dizi faktörün etkisi altında gerçekleşmektedir. Ayrıca, işletme büyüklüğü ve arazi parçalanması, arazi mülkiyeti, çiftçi örgütlenmesi, sosyal yapı, eğitim ve araştırma tesisleri, toprak yapısı ve iklim koşulları gibi faktörler de tarım verimliliğini etkilemektedir (Çelik, 2000).

Gıda ve tarım, ekonomik, sosyal ve çevresel açıdan sürdürülebilir bir yaşam için önemlidir. Tarımsal teknolojilerdeki gelişmelere rağmen, verimlilik artışı sınırlı kalmaktadır. Doğal kaynakların bozulması, biyoçeşitlilik kaybı, bitki hastalıkları ve zararlıları ile mücadele zorlu hale gelmektedir. Girdi ve sermaye yoğun tarım sistemleri, ormansızlaşma, su kıtlığı ve yüksek sera gazı emisyonları sürdürülebilir gıda ve tarımsal üretimde kaybına neden

olmaktadır. Bu sorunların giderilmesi için, tarımın sürdürülebilirliğini artırmak ve gıda güvenliğini sağlamak için politika ve stratejilerin geliştirilmesi gerekmektedir. Daha verimli kullanımı ve kaynakların korunmasını sağlayacak yenilikçi çözümler üzerinde çalışılmalar yapılmalıdır (FAO, 2017).

Kırsal alanlar, ekonomik, sosyal ve mekânsal değişimlerle birlikte farklı yapılar kazanmıştır. Bu alanlar, doğal ve çevresel yapılarıyla ön plana çıkmaktadır. Son yıllarda kırsal alanlar, tarımsal üretim merkezleri olarak görülmekte ve bu alanlardaki kalkınma sorunlarına ekonomik temelli çözümler aranmaktadır. Tarım modernizasyonu da bu süreçte desteklenmiştir, ancak hedeflenen gelişme kırsal alanlarda gerçekleşmemiştir (Ellis & Biggs, 2001).

2000 yılından itibaren çeşitli reformlar ışığında tarımsal gelişmeye etki edecek tarımsal destek araçları Türkiye'nin çeşitli reformlar ışığında tarımsal gelişmelere katkı sağlayacak tarımsal destek araçları bulunmaktadır. Bunlar; doğrudan gelir desteği, girdi desteği, fark ödeme sistemi, telafi edici ödemeler, tarım sigortası desteği, hayvancılık destekleri, kırsal kalkınma destekleri ve diğer destekler olarak gruplandırılabilirler.

1. Doğrudan Gelir Desteği, Türkiye'de 2000 yılında başlamış olup, üretimden bağımsız veya belli bir ölçüde bağımsız olarak tanımlanmaktadır. Doğrudan gelir desteği sistemi, çiftçilere yapılan sabit destekleri içermekte ve piyasada gerçekleşen fiyatları etkilemeden çiftçilere gelir sağlamaktadır. Ayrıca, piyasa koşullarına göre fiyat oluşumunu etkilemek ve yanlış politikalar nedeniyle bütçe üzerinde gereksiz finansman yükünü azaltmak da hedeflenmektedir (Yavuz, 2005).

2. Girdi Desteği (Sübvansiyon), tarımsal üretimde kullanılan girdiler arasında tohum, gübre, mazot, sulama, kimyasal tarım ilaçları, yem ve tarımsal krediler yer almaktadır. Bu girdilerin kullanımını iyileştirmek için yapılan müdahaleler, yatırımlar ve destekler tarımsal girdi politikası olarak adlandırılmaktadır (Yavuz & Dilek, 2019, s. 80).

3. Fark Ödeme Sistemi (Prim Destekleri), Prim sübvansiyonları, üreticilerin gelirini güvence altına almak ve üretimi artırmak amacıyla devlet tarafından yapılan doğrudan ödemelerdir. Bu sübvansiyonlar, hedef fiyat ile piyasada gerçekleşen fiyat arasındaki farkı ifade etmektedir (Russo, 2007).

4. Telafi edici ödemeler (Alternatif ürün programı), tarım reformu uygulama projesi, tarım alanında aşırı üretim ve düşük arz sorununu çözmek için telafi edici önlemler sunmaktadır. Bu önlemler, üreticilere alternatif ürünler üretmeleri için teşvik sağlamayı amaçlamaktadır. Üreticiler, alternatif ürün programı kapsamında ürettikleri ürün dışında başka

bir ürün üretirlerse, bu programdan herhangi bir gelir elde etmemektedir. Ancak alternatif ürünün kaybını önlemek için üreticilere ödemeler yapılmaktadır (Tarım Kanunu, 2006).

5. Tarım sigortası desteği, tarım sektöründe, yangın, sel, heyelan, don gibi doğal felaketler sonucu ortaya çıkan maddi kayıpların karşılanması için sigorta destek ödemeleri yapılmaktadır. Türkiye'de tarım sigortası desteği ilk kez 1957 yılında dolu zararları için sağlanmıştır. Tarım sektöründeki risk yönetimine katkıda bulunmak amacıyla 2005 yılında Tarım Sigortaları Havuzu kurulmuştur (Yazgı & Olhan, 2017).


6. Hayvancılık destekleri, dünyada olduğu gibi Türkiye'de de hayvancılık sektörü, hızla artan nüfusun ihtiyaçlarını karşılamak için önem taşımaktadır. Dengeli beslenme, endüstriyel hammadde ve kırsal alanların etkin bir şekilde kullanılması, hayvancılık sektörünün gelişimi için stratejik bir öneme sahiptir (Aral & Sakarya, 1996; Yılmaz & Köknaroglu, 2007). Bu nedenle hayvancılık için izlenen politikalar ve destekler son derece önemli hale gelmektedir. Hayvancılık politikalarının ve desteklerin amacı, dengeli beslenme için gerekli hayvansal protein üretimini artırmak ve daha kaliteli ve ekonomik ürünler sunmaktır. Bu amaçla, üretim sürecinin iyileştirilmesine yönelik çalışmalar yapılması gerekmektedir (Demir, 2012).

7. Kırsal kalkınma destekleri, kırsal kalkınma, uzun soluklu ve çok boyutlu bir süreç olup, farklı paydaşların birlikte hareket etmesini gerektirmektedir. Kaynakların etkin ve verimli kullanılması ve paydaşlar arasında koordinasyon, kırsal kalkınmanın elde edilmesinde önemli bir etkiye sahiptir. Tarım ve Kırsal Kalkınmayı Destekleme Kurumu (TKDK), kırsal kalkınmada önemli bir rol oynamaktadır. TKDK ve diğer paydaş kurumlar, kırsal alanlarda ekonomik kalkınmanın sağlanması ve üreticilerin gelir düzeylerinin artırılması amacıyla kırsal kaynakları harekete geçirmeye çalışmaktadır (Özdemir & Efe, 2013, s. 67). Tarım ve Kırsal Kalkınmayı Destekleme Kurumu (TKDK) ile Avrupa Birliği Ortak Tarım Politikası arasında bir ilişki bulunmaktadır. Avrupa Birliği Ortak Tarım Politikası, tarımsal verimliliği artırmayı, tarımda çalışanlara adil yaşam standartları sağlamayı, piyasaları istikrara kavuşturmayı, gıda arzını garanti altına almayı ve tüketicilere uygun fiyatlı arz sağlamayı hedeflemektedir. Bu hedefler, kırsal kalkınma üzerinde olumlu bir etkiye sahiptir. Ancak, 2008 küresel krizinin TKDK'nın faaliyetlerini ve Ortak Tarım Politikasını etkilediği ve bu durumun Türkiye ve diğer ülkelerde olumsuz sonuçlara neden olduğu belirtilmektedir (Tarım ve Orman Bakanlığı Raporları, 2022).

1.4.1. Tarımsal Destekleme Ödemelerinin Bütçe İçerisindeki Payı

Tarımsal destekleme ödemeleri, Türkiye'nin bütçesinde önemli bir yer tutmaktadır ve tarım sektörüne yapılan bu ödemelerin büyüklüğü, ekonominin sürdürülebilirliğini sağlamada kritik bir rol oynamaktadır. Tarımsal destekleme ödemelerinin bütçe içindeki payı, özellikle

kırsal kalkınma ve tarım sektörünün desteklenmesi amacıyla ayrılan kaynaklar doğrultusunda yıllık olarak değişiklik göstermektedir. Bu ödemeler, üreticilerin girdi maliyetlerini hafifletmek, üretim kapasitesini artırmak ve kırsal alanda istihdamı teşvik etmek gibi hedeflere yönelik kullanılmaktadır. Türkiye'de tarımsal desteklerin bütçe içindeki oranı, genellikle bütçenin büyük bir kısmını oluşturan sosyal harcamalarla karşılaştırıldığında, nispeten daha düşük olmakla birlikte, sektöre yapılan yatırımların artırılması, tarımsal üretimde verimliliği desteklemektedir (CSBB, 2023).



Şekil 5: Merkezi Yönetim Bütçe Harcamaları İçinde Tarımsal Destekleme Ödemeleri (Milyon TL) ve Bütçe İçindeki Paylar (%) (2006- 2024) (SBB, 2024)

Şekil 5 incelendiğinde 2006 yılında 4.747 milyon TL olan tarımsal destekleme ödemeleri, 2024 yılına kadar kademeli olarak artmış ve 2024'te 91.554 milyon TL'ye ulaşmıştır. Özellikle 2022 yılında ödemelerde dikkat çekici bir sıçrama görülmektedir; 2021'de 24.125 milyon TL olan destekler, 2022'de yaklaşık iki katına çıkarak 39.642 milyon TL'ye yükselmiştir. Bu artış, tarım sektörüne yönelik devlet desteğinin son yıllarda önemli ölçüde artırıldığını göstermektedir. 2023 ve 2024 yıllarında da bu artış eğilimi devam etmekte ve 2024 yılında en yüksek seviye olan 91.554 milyon TL'ye ulaştığı görülmektedir.

Tarımsal destekleme ödemelerinin bütçe içindeki payı 2006 yılında %2,66 iken, 2007 yılında %2,72 ile en yüksek seviyeye ulaşmıştır. Ancak 2009'dan itibaren bu oran düşmeye başlamış, 2022 yılında %0,8 ile en düşük seviyeyi görmüştür. 2023 ve 2024 yıllarında bütçe içindeki pay %1'e yükselmiştir, ancak 2006-2011 yıllarındaki %2'nin üzerindeki seviyelere kıyasla hala oldukça düşük seyretmektedir.

Son yıllarda destek ödemelerinde görülen artış, özellikle pandemi sonrası dönemde tarım sektörüne yönelik teşviklerin artırıldığına işaret etmektedir. Ancak bütçe içindeki payın nispeten düşük kalması, sektörel kaynak dağılımında tarımın görece daha düşük bir pay aldığını göstermektedir.

1.5. GENEL ANLAMDA KREDİ KAVRAMI

Kredi, gelecekteki bir tarihte ödeme yapma taahhüdüdür ve bir anlaşma çerçevesinde mal veya hizmet alımı veya satın alma gücü sağlama şeklinde ekonomik bir varlık olarak tanımlanmaktadır. Kredi, vaat tarihinde kredi verilen kişi veya kişilerin kullanımına veya üçüncü bir tarafa itibarından yararlanma fırsatı sunmaktadır. Kredi, finansal prestij anlamına gelir ve ekonomik faaliyetlerin sürdürülmesi için önemli bir kaynaktır (Tunaboğlu, 1977).

Genel olarak kredi, bir varlığın belirli bir süreliğine devredilmesi ve bu varlığın belirlenen süre sonunda geri ödenmesi veya garanti altına alınması şartıyla sağlanan bir finansal işlem olarak tanımlanabilir. Kredinin temeli, takas esasına dayalı bir ilişkiye dayanır ve bu bağlamda, bir kişi veya kuruluş, kendisine ait olmayan bir hak ya da yetkiye sahip olamaz. Kredinin bu özelliği, taraflar arasında güvene dayalı bir ilişkinin kurulmasını ve işlemin karşılıklı taahhütlere uygun bir şekilde yürütülmesini gerektirir. Krediyi alan taraf, tesis veya fonu belirli bir süre için kullanma hakkına sahip olurken, krediyi veren taraf ise önceden belirlenmiş bir bedelin geri ödenmesini taahhüt etmektedir. Kredi, fon sağlayan ve fon talep eden taraflar arasında bir güven ilişkisinde olup, ekonomik bir değiş tokuşu temsil etmektedir (Aras, 1995).

Kredi, ekonomik faaliyetlerin sürdürülebilmesi için gereken fon ihtiyacını karşılar ve işletmelere piyasada var olma imkânı sağlamaktadır. Bu durum istihdamın artmasına ve milli gelire pozitif katkı sağlayamaya yardımcı olmaktadır. Kredi sistemi, kullanılmayan fonları kredi olarak ihtiyaç sahiplerine aktararak ekonomide arz ve talep dengesini sağlamaktadır. Yatırımcılar ve girişimciler kredi kullanarak yatırımlarını gerçekleştirir ve ihtiyaç duydukları sermayeyi elde etmiş olurlar. Krediler, bankalar tarafından sağlanan kaynaklar olduğu için ekonomik kalkınmanın sağlanması için önemli bir mali kaynak olarak kabul edilmektedir. Ayrıca kredi kullanımı, nakit kullanımını azaltır ve ticari işlemlerin hızlanmasına yardımcı olmaktadır. Kredi, ekonomide dolaşım aracı olarak da kullanılmaktadır ve ekonomik aktivitelerin sürdürülebilirliğini de sağlamaktadır (Yanık, 2008).

1.5.1. Kredinin Unsurları

Kredinin tanımından yola çıkarak kredinin temel unsurlarını güven unsuru, vade unsuru, risk unsuru ve gelir unsuru olarak dört maddede sıralayabiliriz.

1. Güven Unsuru, kredi de esas olan faktör güven olmaktadır. Krediyi sağlayan kişi veya kuruluşlar verilen kredinin vadesi geldiğinde geri ödenmemesi riskine karşılık olarak teminat talep etmektedir. Teminatın karşılığı krediyi verenin riske karşı oluşturduğu bir değer olarak ortaya konulmaktadır (Cole & Mishler, 1998).

2. Vade Unsuru, kredilerin geri ödenmesi için belirli bir vadeleri bulunmaktadır. Bu vadenin uzunluğu kredinin riskini artırmaktadır. Sürenin uzunluğu kredi verme sürecinde oldukça önemli olmasının nedeni geleceğin sosyo-ekonomik açıdan belirsiz olmasıdır. Kredinin geri ödenmesi için belirlenen süre boyunca teminatın sağlanması gerekmektedir. Kredinin süresi kredi işleminin başlangıcında belirlenmektedir (Perçin, 1999).

3. Risk Unsuru, bankacılıkta risk, ödünç verilen paraya ve verilen teminata ilişkin risk olarak tanımlanmaktadır. Risk, taahhüdün yerine getirilmesine kadar gerçekleşebilecek tehlikelerin toplamını ifade etmektedir. Yani bir kişi veya kuruluşa nakit, mal, kefalet veya teminat şeklinde verilen bir taahhüdün yerine getirilmesine kadar ortaya çıkabilecek olası tehlikelerin toplamını temsil etmektedir. Bu nedenle, bir kredi işlemindeki risk unsuru en aza indirilmeli ve kontrol altında tutulmalıdır (Perçin, 1999).

4. Gelir Unsuru, bankaların gelirlerini artırmak için kredi verirken komisyonlar tahsil etmesi önem arz etmektedir. Bankalar, mevduat toplayarak, kredi vererek ve diğer hizmetleri sunarak gelirlerini artırmayı sağlamaktadır. Komisyonlar, bankaların işlemlerinden kaynaklanan maliyetlerini karşılamaya yardımcı olmakta ve bankalara ek bir gelir kaynağı sağlamaktadır (Durak, 2000).

1.5.2. Kredinin İşlevleri

Krediler, finans ve sermaye piyasalarının yanı sıra reel piyasaları da etkilemektedir. Bu nedenle, kredilerdeki herhangi bir gelişme, tüm ekonomik ve ticari faaliyet alanlarına etki etmektedir. Kredilerin üç temel işlev olarak sıralanabilir.

1. Ekonomik İşlevi: Bankaların temel ekonomik işlevi, finansal aracılık sağlamaktır. Bankalar, fazla tasarruf eden kişilerden fon toplarken, tasarruf açığı olan kişilere de nakit transferi yapmaktadır. Bu sayede ülkedeki fon ihtiyacı karşılanır, yatırım ve üretim faaliyetlerinin hızla artışa geçmesi sağlanır. Ayrıca bankaların kredi faaliyetleri sayesinde atıl tasarruflar değerlendirilir ve sermaye birikimi sağlanmaktadır. Bu işlevleriyle bankalar, ülkenin ekonomik büyümesine katkıda bulunmaktadır (Erdem, 2010).

2. Tüketim İşlevi: Ekonomik karar birimlerine kredi sağlanmasıyla ticari faaliyetlerin kesintisiz devam etmesini sağlamaktadır. Özellikle ekonomik durgunluk dönemlerinde, bankaların sağladığı kredilerle bireylerin tüketim harcamaları artar ve piyasalarda canlılık artar. Bu durumda üretim düzeyinde artışlar yaşanır. Tüketim harcamalarının artması, refah seviyesinde yükselmeyi artırır. Kredilerin mal ve hizmet alımlarını finanse etmesi, bireylerin gelirlerini artırır ve ekonomik büyümeye katkı sağlamaktadır (Yılmaz, 2011).

3. Kaldıraç işlevi: Sürdürülebilir büyüme hedefleyen firmalar için sermaye birikiminin yeterli olmadığı durumlarda destek sağlamaktadır. Bu firmalar genellikle işletme

sermayesini artırmak için kredilere başvurmaktadır. Kredi alımıyla birlikte ortaya çıkan kaldıraç etkisi, kredinin artmasıyla birlikte daha da güçlenmektedir. Bu durumda, kaldıracın etkisi de artmaktadır. Kaldıraç, şirketlerin karını artırma, sermaye verimliliğini yükseltme ve finansal riski yönetme konularında önemli bir faktördür (Tevfik, 2005).

1.5.3. Veriliş Amacı Açısından Krediler

Veriliş amaçları olarak kredileri üç farklı şekilde sıralanabilir. Kredilerin hangi amaçla kullanıldığı ve ne için kullanılacağına göre sınıflandırılmaktadır.

1. Tüketim Kredileri: Gerçek kişilerin ticari olmayan ihtiyaçlarını finanse etmek için kullandıkları kredilerdir (Babuşcu & Hazar, 2017, s. 154).

2. İşletme Kredileri: İşletmelerin işletme sermayesi ihtiyaçlarını karşılamak için kullandıkları kısa ve orta vadeli kredilerdir. Bu krediler, işletmelerin sermaye eksikliklerini gidermek amacıyla verilmektedir (Parasız, 2000).

3. Yatırım Kredileri: Yeni işletmelerin sabit varlık yatırımlarını finanse etmek için kullanılan uzun vadeli kredilerdir. Bu krediler, bina, makine ve tesis gibi sabit varlık yatırımlarının finansmanına yardımcı olarak kullanılmaktadır (Sarı, 2020).

1.6. TARIM KREDİLERİ

Tarım sektörünün sürekli olarak artan finansmana ihtiyaç duyulmaktadır. Çiftçilerin gelir elde etme dönemleri belirli olsa da giderlerin uzun bir zaman aralığına yayılması ve çiftçilerin tasarruf eksikliği gibi nedenlerle tarımsal krediler önemli bir rol oynamaktadır. Ayrıca, modern tarım teknolojilerinin sermaye gereksinimleri de tarımsal krediler aracılığıyla karşılanmaktadır. Bu durum, çiftçilerin tarım işletmelerini geliştirebilmeleri ve verimliliklerini artırabilmeleri için finansal kaynak sağlamaktadır (Pandey, 2008).

Tarımsal krediler, tarımsal işletmelerin faaliyetlerini sürdürebilmek veya genişletebilmek için kullandıkları bir finansman aracıdır. Bu kredi, üretim girdileri, ekipmanlar ve ikinci el sabit varlıkların satın alınması gibi çeşitli amaçlar için kullanılabilir. Tarımsal kredi, tarım üreticilerinin mali zorluklarla karşılaştığında veya yatırım ihtiyaçları olduğunda başvurabilecekleri bir kaynak olarak da hizmet vermektedir. Tarım sektöründe faaliyet gösteren bankalar, tarım kredi kooperatifleri, araç ve ekipman tedarikçileri gibi kaynaklar da tarımsal kredilere erişim sağlamaktadır. Tarımsal kredinin kaynağı, kayıtlı veya kayıt dışı yollardan temin edilebilen her türlü yabancı kaynak olarak ifade edilebilir (Ersoy & Özsoy, 2017).

Tarım kredileri, çiftçilerin modern tarım imkanlarından faydalanmalarına ve ihtiyaçlarını karşılamalarına yardımcı olmaktadır. Aynı zamanda tarım girdilerinin daha uygun

bir şekilde temin edilmesini sağlar ve bu şekilde toplam üretimi ve verimliliği artırmaya destek olmaktadır (Foltz, 1998). Tarımsal krediler, gelişmekte olan ülkelerdeki kırsal alanların kalkınmasında büyük bir rol oynamaktadır. Zamanında ve yeterli miktarda sağlanan krediler, tarım verimliliğini artırarak üreticilerin refahını yükseltmektedir. Tarım sektörünün gelişmesi, genel olarak ekonominin ve kalkınmanın iyileştirilmesine önemli bir katkı sağlamaktadır. Aynı zamanda kırsal kesimin gelir ve refah düzeylerini artırmasının yanı sıra, toplumda sosyal adalet ve eşitlik sağlanmasında da önemli bir araçtır (Khan vd., 2007).

Türkiye'de tarım sektörü, çiftlik yönetimi ve tarımsal üretim arasında sıkı bir bağ bulunmaktadır. Tarım, Türk çiftçisinin hane halkı yönetimi ve tarımsal üretim faaliyetleriyle birlikte yürütülmektedir. Çiftçilik genellikle aile tarafından yapılan bir faaliyettir ve sosyo-ekonomik olarak önemli bir rol oynamaktadır. Tarım faaliyeti, sadece bir ekonomik geçim kaynağı değil, aynı zamanda bir yaşam biçimidir. Türkiye'nin tarım sektörü, tarım işletmelerinin ve çiftliklerin varlığıyla güçlenmektedir. Bu nedenle, tarımsal üretim ve çiftlik yönetimi birbirinden ayrılmaz bir şekilde bir araya gelmektedir (Bülbül, 2006, s. 59). Türkiye'deki tarımsal işletmelerin çoğunluğu küçük çiftçilerden oluşmaktadır. Bu işletmeler genellikle yeterli sermayeye sahip olmadığı için tarımsal krediye ihtiyaç duymaktadır. Tarım arazilerinin parçalı olması da kredi almayı zorlaştırmaktadır. Ancak bu durum kredi ihtiyacını artırmakta, kredinin kontrolünü zorlaştırmakta ve kredi maliyetini yükseltmektedir (Karacan, 1991).

Tarım sektöründe üretim sürelerinin kısaltılması zordur ve vardiyalı çalışma sanayi sektöründe olduğu gibi tarımda da mümkün değildir. Bu sektörde çiftçinin mahsulünü hasat etmesi çok kısa bir süre içinde gerçekleşir ve bu süre boyunca işletme sermayesine sürekli ihtiyaç duymaktadır. Bu durum tarımsal kredi ihtiyacını artıran bir diğer faktördür (Bülbül vd., 1995).

Tarım sektöründe teknoloji ve makineleşme için daha fazla sermaye yatırımına ihtiyaç duyulmaktadır. Bununla birlikte, günümüz tüketicilerinin hızla değişen ve çeşitlenen tercihleri, pazar taleplerine hızlı bir şekilde cevap verebilme gerekliliğini artırmaktadır. Ayrıca, ambalajlama, hızlı taşıma ve reklam maliyetleri gibi faktörler de kredi ihtiyacını artırmaktadır (Karacan, 1991).

Tarım ürünleri arzının inelastik olması, istenen miktar ve hızda artırılamamasına işaret etmektedir. Yani tarımsal ürün arzı, talepteki bir artışa hızlı bir şekilde cevap verememektedir. Bu durumda, tarımsal ürün arzındaki bir artışın hemen fiyatların düşmesine yol açtığı görülmektedir. Fiyatlardaki düşüş ise çiftçilerin gelirlerinde beklenmedik bir azalmaya neden

olmaktadır. Bu da tarımsal işletmelerde ek sermaye ihtiyacını artırıp kredi ihtiyacını ortaya çıkarmaktadır (Karacan, 1991).

1.6.1. Tarımda Finansman Kaynakları

Tarımsal faaliyetler sırasında finansal kaynaklara ihtiyaç duyulur. Bu kaynaklar öz sermaye ve yabancı kaynaklardır.

1. Öz kaynak finansmanı, girişimlerin kurucularının girişimin finansmanı için kendi varlıklarından ayırdıkları fonları ifade etmektedir. Bu fonlar, işletmelerin maddi ve maddi olmayan varlıklarını oluşturmaktadır. Tüm işletmeler için en uygun finansman türü öz kaynakla sağlanan finansmandır. Öz kaynak finansmanı ile işletmeler, kendi sermayelerini kullanarak yabancı kaynaklardan finansman sağlamak yerine kendi kaynaklarını işletmelerine finanse etmeyi tercih etmektedirler. Ancak tarımsal işletmelerde öz kaynak finansmanını zorlaştıran bazı nedenler bulunmaktadır. Bu nedenler arasında öz kaynak devir hızının düşük olması, yüksek girdi fiyatları, küçük aile işletmelerinin fazlalığı ve parçalı arazi yapısı bulunmaktadır. Öz kaynak finansmanı, devlet desteği politikalarıyla işletmeleri kendi kendine yeterli hale getirebilmektedir (Erdaş, 2012).

2. Yabancı Kaynaklar, bir işletme, kurumsal veya kurumsal olmayan dış kaynaklardan borçlanarak sermaye sağlayabilmektedir. Öz kaynaklardan elde edilen sermaye genellikle uzun süre kullanılırken, yabancı kaynaklardan elde edilen sermaye daha kısa vadeli. Yabancı kaynaklardan sağlanan finansman, borcun ne zaman geri ödeneceğinin önceden belirlendiği veya borç verenin talep ettiği zaman geri ödenebileceği bir anlaşma çerçevesinde gerçekleşmektedir. Bu nedenle, yabancı kaynaklarla sağlanan sermayenin likidite derecesi öz kaynaklara göre daha düşüktür (Çetin, 2020). Yabancı kaynaklar ve öz sermaye ile sağlanan finansman işletmeler için vade ve faiz yükü açısından farklılık göstermektedir. Tarım sektöründe ise tarımsal finansmanın kendine özgü özellikleri bulunmaktadır. Tarım sektörü için sağlanan finansmanın uzun vadeli olması ve faiz oranlarının diğer kredi türlerine göre düşük olması gerekmektedir (Erdaş, 2012).

Tarım sektörü, doğal afetlerin etkilerine karşı oldukça savunmasız bir sektördür. Yağmur, kuraklık, don, dolu, kar, fırtına ve sel gibi meteorolojik olaylar tarımsal üretimde ciddi hasarlara yol açabilmektedir. Bu risklerin önlenmesi için seralar, sulama sistemleri ve çit gibi önlemler alınabilir, ancak tamamen önüne geçmek mümkün değildir. Bu nedenle, üreticiler hasarlarla başa çıkmak için kredi kullanmayı tercih etmektedirler.

1.6.2. Tarımsal Kredilerin Sınıflandırılması

Tarımsal krediler kısa, orta ve uzun vadeli olmak üzere üç kategoriye ayrılmaktadır. Kısa vadeli krediler, bir yıl veya daha kısa bir sürede geri ödenen kredilerdir. Bu tür krediler genellikle çiftlik ihtiyaçları gibi kısa vadeli finansman gerektiren konuları desteklemek için kullanılmaktadır. Bu krediler, çiftlik maliyetlerinin veya geçici nakit akışı ihtiyaçlarının karşılanması için tercih edilen bir finansman kaynağıdır (Karacan, 1991).

Orta vadeli tarımsal krediler, makine, ekipman, envanter veya canlı hayvan alımı ve arazi ıslahı gibi amaçlar için kullanılmaktadır. Bu kredilerin vadesi bir ile beş yıl arasında değişmektedir. Kredinin kullanım amacı göz önünde bulundurulduğunda, başlangıç noktası, kredi süresi ve vadesi belirlenirken yatırım yapılan alanın getirisinin dikkate alınması önemlidir. Uzun vadeli krediler ise beş ile yirmi yıl arasında değişen vadelerle kullanılmaktadır. Uzun vadeli krediler, işletme edinme ve çiftlikte kalıcı yatırımlar yapma amacıyla kullanılmaktadır (Karacan, 1991).

Tarımsal üretim kredileri işletme ve yatırım kredileri olarak iki gruba ayrılmaktadır. İşletme kredileri, bitkisel ve hayvansal üretim, su ürünleri yetiştiriciliği veya av çiftliklerinin sermaye ihtiyaçlarını karşılamak için kullanılan kısa vadeli kredilerdir. Bu krediler, tohum, gübre, böcek ilacı ve fide alımı gibi bitkisel üretim için kullanılırken, hayvansal üretimde yem, ilaç, aşı ve veterinerlik hizmetleri gibi harcamaları karşılamak için kullanılmaktadır. Aynı şekilde işletme kredileri, makine bakımı, onarımı, yakıt giderleri, depolama ve nakliye masrafları gibi ihtiyaçları da karşılamaktadır. Tarım sigortası ihtiyaçlarını karşılamak için kullanılan krediler ise operasyonel krediler olarak sınıflandırılmaktadır (Ziraat Bankası, 2013).

Tarımsal yatırım kredileri, bitki, hayvan ve su ürünleri yetiştiriciliği için kullanılmaktadır. Bu krediler, yeni tarımsal işletmelerin kurulması veya satın alınması, işletmelerin kapasitesinin artırılması, hayvan, makine ve ekipmanların modernizasyonu ve satın alınması için kullanılmaktadır. Ayrıca canlı hayvan üretimi ve diğer sabit varlıkların satın alınması, mobilya ve ekipman alımı, ahır, ağıl, kümes, sera, soğuk hava deposu, sulama sistemleri gibi yatırımlar için de kullanılmaktadır (Ziraat Bankası, 2013).

Tarımsal sanayi kredileri; tarımsal ürünlerin işlenmesi için tesis kurma, tarımsal işletmelerin kendi becerileriyle üretim yapma ve modern ekipman kurma gibi amaçları bulunmaktadır. Bu krediler aynı zamanda soğutma depoları ve paketleme tesislerinin kurulumunu, gerekli malzemelerin sağlanmasını ve ulaşım araçlarının teminini içermektedir (Karacan, 1991).

Tarımsal kredi veren bankalar, çiftçilerden ahlaki karakterleri, iş kapasiteleri, yükümlülüklerini yerine getirme kabiliyetleri, tarımsal üretimlerinin özellikleri, mali durumları ve kredinin süresi gibi faktörlerin yanı sıra farklı teminatlar da talep edebilmektedir. Bu teminatlar, tarımsal kredilerin sınıflandırılmasında da rol oynamaktadır. Gayrimenkul ipotekleri, taşınmaz ipotekleri, gerçek veya tüzel kişi garantileri, araç veya traktör rehinleri, kefalet senetleri, nakit rehinleri, alacağın temliki, çek veya senet teminatları gibi teminat türleri, garanti kuruluşları tarafından rehin, makbuz ve taahhüt rehini olarak talep edilebilmektedir (Ziraat Bankası, 2010).

1.6.3. Türkiye’de Tarımsal Kredi Sağlayan Kuruluşlar

Türkiye’de tarımsal alanda kredi sağlayan kuruluşların başında Ziraat Bankası, Tarım Kredi Kooperatifleri ve diğer bankaların yer aldığı görülmektedir (Özçelik vd., 2005). Ziraat Bankasının yanı sıra diğer kamu bankalarının da sağladığı tarımsal krediler mevcuttur.

1.6.3.1. Bankalar ve tarım kredi kooperatifleri

Türkiye’de tarımsal kredi talebi, artan nüfus ve gelişen ekonomi nedeniyle her geçen gün artmaktadır. Bu talebe yanıt olarak, kamu ve özel bankalar tarım bankacılığı bölümleri açmıştır. Bu şekilde, tarımsal krediye erişim kolaylaştırılmış ve çiftçilere alternatif kredi olanakları sunulmaya başlanmıştır (Güneş & Movassaghi, 2017).

Türkiye’deki kamu bankaları, tarım sektörüne kredi vermeye devam etse de, özel bankaların da kredi piyasasında önemli bir rol oynamaya başladığı görülmektedir. Özel bankaların tarıma yönelik faaliyetlerinin artmasının nedenlerinin başında, diğer sektörlerdeki düşen kar marjları ve komisyonlar olması bankaların bu sektöre olan ilgisi artmaktadır. Bu nedenle, özel bankalar daha karlı olan tarım sektörüne daha fazla ilgi göstermektedir. Ayrıca, kırsal kesimdeki üreticilerin ödeme ahlakının diğer kredi müşterilerine göre daha yüksek olduğu görülmektedir. Bununla birlikte, tarımsal krediler için tarım arazilerinin ipotek olarak alınması veya çiftçilerin kefil olarak gösterilmesi gibi uygulamaların sıkıntılı kredilerin tahsil edilmesi açısından büyük bir öneme sahip olduğu görülmektedir. Bu durum, özel bankaların tahsilat kapasitelerini artırmasına ve güvende hissetmelerini sağlamaktadır.

Ziraat Bankası, tarım sektörü için ana kredi kuruluşu olarak görev yapan bir bankadır. Tarımsal krediler ve tarımsal ürün satışlarının finansmanını sağlamaktadır. Ayrıca kooperatif kredileri ve devlet sübvansiyonlu kredilerin birçoğu da Ziraat Bankası aracılığıyla sunulmaktadır. Banka, farklı bankacılık faaliyetleriyle uğraşsa da asıl amacı tarımsal üreticilere üretim ve yatırım kredileri sağlamaktır (Ziraat Bankası, 2021).

Ziraat Bankası, tarım sektöründe faaliyet gösteren çiftçilere kredilendirme yoluyla destek sağlamaktadır. Bu kapsamda, banka çiftçilerin mevcut çiftliklerini ya da yeni tesislerini finanse etmelerine yardımcı olmaktadır. Ziraat Bankası, tarımsal kredi sağlayan lider bir banka konumundadır. Tarım ve Kırsal Kalkınma Bakanlığı tarafından belirlenen tarımsal kredi politikasını uygulamaktadır. Ziraat Bankası tarafından sağlanan tarımsal kredilerin geri dönüşü sağlanacak şekilde dayanıklı ve sürdürülebilir tarım projelerine yönlendirilmektedir. Bu sayede, tarımsal üretimin artırılması ve ulusal ekonomiye katkı sağlanmaktadır (Taşkıran & Özudoğru, 2010).

Ziraat Bankası, yerli traktör üretimi ile başlayarak çiftçilere modern traktörler ve mekanik ekipmanların üretimini finanse etmektedir. Bunun yanı sıra, verimli tohum kullanımı, kimyasal gübre ve haşere kontrolü gibi birçok alanda çiftçilere kredi verilerek destek sağlanmaktadır. Sulama sektöründe de bankadan alınan kredilerle birçok yatırım yapılmaktadır. Türkiye'nin tarımsal ihracatı ise meyve yetiştiriciliği gibi alanların geliştirilmesiyle çeşitlendirilmiştir. Hayvancılık ve mera ıslahı gibi alanlarda da tarıma yönelik krediler sunulmaktadır. Ziraat Bankası, Türkiye'deki süt üretiminin en büyük finansörüdür. Ayrıca arıcılık ve ipekböceği yetiştiriciliği gibi uzmanlık gerektiren alanlarda da çiftçilere tarımsal kredi sağlanmaktadır (Ziraat Bankası, 2018a).

Ziraat Bankası, tarımsal kredi desteği sunarak diğer bankalardan farklılaşmaktadır. Banka, çiftçilere ve üreticilere çeşitli tarım kredileri sunmaktadır. Hayvancılık ve su ürünleri kredileri, bitkisel üretim kredileri, mekanizasyon kredileri ve kartları gibi hizmetler sunmaktadır. Ayrıca, iş edinme kredileri, hasat ve pazarlama kredileri, tarımsal taksitli krediler, lisanslı hisse senedi yatırımları, genç çiftçilere verilen krediler, organik tarım için verilen krediler, arazi edinimi için krediler, üretim desteği için krediler, nakliye araçları için krediler, elektronik depo makbuzları karşılığı krediler gibi farklı kredi türleri sunmaktadır. Ziraat Bankası, tarımsal kredilendirme konusunda geniş bir yelpazeye sahiptir. Küçük ve orta ölçekli işletmelerin ihtiyaçlarına yönelik çözümler sunmaktadır (Ziraat Bankası, 2018).

Ziraat Bankası, deniz, içme su ve beton/toprak su ürünleri yetiştiriciliği için kredi vermekte ve bu kredi türü işletme kredileri ve yatırım kredileri olmak üzere iki kategoriye ayrılmaktadır. İşletme kredileri, su ürünleri yetiştiriciliği faaliyetlerini finanse etmek amacıyla kullanılmaktadır. Bu kredilerle alet, ekipman, bakım, onarım, sigorta, kasa gibi masraflar karşılanabilmektedir. Yatırım kredileri ise avcılık ve yetiştiricilik ekipmanlarının alımı, üretim havuzu, soğuk oda, motor, tekne, balıkçı gemisi, balık bulma sistemleri, balık ağları gibi binaların inşası ve satın alma işlemleri için kullanılmaktadır. Krediler ayrıca avcılık ve yetiştiricilikle ilgili diğer alımların finansmanını da kapsamaktadır (Ziraat Bankası, 2018).

Halkbank, küçük tüccarlar, zanaatkârlar ve KOBİ'lerin finansman ihtiyaçlarını karşılamak için hizmet veren bir bankadır. Banka, kısa vadeli işletme sermayesi ve orta vadeli makineler gibi çeşitli finansman imkanları sunarak işletmelerin işlerini geliştirmelerini ve üretimlerini artırmalarını desteklemektedir. Ayrıca, banka işletmelerin değerlendirilmesi için de çözümler sunmaktadır. Halkbank, küçük ve orta ölçekli işletmelerin büyümelerini desteklemek ve daha rekabetçi hale gelmelerine yardımcı olmak amacıyla faaliyet göstermektedir. Bankanın hizmetleri geniş bir kitleye yönelik olduğu için hem küçük tüccarlar ve zanaatkârlar hem de KOBİ'ler için cazip bir seçenek haline gelmiştir (Takan & Boyacıoğlu, 2011).

Vakıfbank, Türkiye'deki vakıf kaynakları ve gelirleriyle, ülkenin ekonomik büyüme ve kalkınma ihtiyaçlarını karşılamak amacıyla 1954 yılında kurulmuştur. Bugün, mevduat bankacılığı faaliyetlerinin yanı sıra yatırım bankacılığı ve sermaye piyasası faaliyetleri de yürütmektedir. Vakıfbank, "Halden Anlayan Tarım Bankacılığı" çerçevesinde tarım sektörüne yönelik faaliyetler yürütmektedir. Bu kapsamda tarım üreticilerinin işletme ve yatırım kredisi ihtiyaçlarını, hasat dönemlerini dikkate alarak karşılamaktadır (Vakıfbank, 2021).

3476 sayılı kanun, 1163 sayılı kooperatifler Kanunu'nun 25. maddesini değiştirerek, 1998 yılında yürürlükte olan 9 farklı kooperatif tüzüğünü yürürlükten kaldırmıştır. Bu değişikliklerle birlikte ana sözleşme, tarımsal kalkınma, sulama, su ürünleri ve pancar plantasyonları olmak üzere 4 kategoriye ayrılmıştır. Seçimler ise ana sözleşme gereği yapılmaktadır. Kooperatifler, tarım endüstrisi için üretilen ürünlerin kullanımı ve kırsal kesimden büyük şehirlere göçün önlenmesi gibi konularda önemli bir rol üstlenmektedir. Bu durum, tarımsal kalkınma için kooperatiflerin önemini artırmaktadır (İnan vd., 2000).

Tarım kredi kooperatifleri, tarım sektöründeki küçük üreticilere ucuz ve yeterli kredi imkânı sağlamak amacıyla kurulmuştur. Bu kooperatiflere başvurarak dış ticaret kaynaklarını karşılamaya çalışanların çoğunlukla küçük çiftçiler olduğu görülmektedir. Küçük üreticiler genellikle bankalardan kredi temin edememekte ve bu yüzden tarım kredi kooperatiflerine başvurmayı tercih etmektedir. Küçük çiftçilerin bankalara teminat olarak gösterecekleri arazileri olmadığı ya da arazi değerinin kullanmak istedikleri kredi miktarını karşılayacak kadar yeterli olmadığı görülmektedir (Mülayim, 1995, s. 200).

Tarımsal kooperatifler genellikle tedarik ve pazarlama faaliyetleri üzerine kurulmuştur. Tarımsal kooperatifler, çiftçilere ucuz girdi kaynakları, uygun kredi ve pazarlama fırsatları sunarak üretim kapasitelerinin artmasına ve gelirlerinin yükselmesine yardımcı olmaktadır. Tarımsal kooperatifler, çiftçilerin kaynaklarını daha etkin bir şekilde kullanmalarını ve daha yüksek kar elde etmelerini sağlamaktadırlar (Çelik, 2012).

Tarım kredi kooperatiflerinin faaliyet alanları arasında kısa ve orta vadeli ihtiyaçların karşılanması, ürünlerin değerlendirilmesi, makine, ekipman ve tesislerin edinilmesi yer almaktadır. Ayrıca, üretim mallarının toplu olarak temin edilmesi, el sanatlarının desteklenmesi, mesleki ve teknik eğitimlerin geliştirilmesi ve değerlendirilmesi, örgütlenme, mevduat kabul etme, bankacılık hizmetleri ve sigorta aracılığı gibi hizmetler de sunmaktadır. Bu kooperatifler ayrıca işgücü konularında da hizmet vermektedir (Sarı, 2000).

Türkiye'de tarım kredileri, tarım sektörünün ekonomik büyümesi, istihdama ve gıda güvenliğine olan katkısı nedeniyle büyük önem taşımaktadır. Özellikle küçük çiftçilerin sermaye eksikliklerini gidermelerine, modern tarım ürünlerine ve teknolojiye erişim sağlamalarına yardımcı olmaktadır. Ayrıca, kırsal kalkınmayı destekleyerek, bölgesel eşitsizlikleri azaltıp, üretimi artırarak ihracat potansiyelini yükseltmeyi amaçlamaktadır. Doğal afetler sonrasında çiftçilerin toparlanmasına katkı sağlayarak, Türkiye'nin yönetim üretim kapasitesinin sürdürülebilirliğine destek olmaktadır. Bu çalışmanın amacı, tarım kredilerini etkileyen göstergeler kullanılarak Türkiye'de verilen tarım kredileri miktarını tahmin etmek için bir tahmin modelleri geliştirmektir. Bu modeller hem istatistiksel yöntem hem de yapay zekâ tabanlı yöntemleri kullanılarak geliştirilecektir.

1.7. LİTERATÜR TARAMASI

Kredi riski analizi, kredi tahmini ve sektörel performans değerlendirmelerine ilişkin çalışmalar, yapay zekâ ve ileri analitik yöntemlerin (AIXT) benimsenmesiyle daha etkin ve kapsamlı bir araştırma alanı haline gelmiştir. Literatürde, yapay sinir ağları (YSA), lojistik regresyon, makine öğrenmesi algoritmaları, mekânsal panel analizler, VAR (Vektör Otoregresyon) ve ARDL modelleri gibi çeşitli yöntemlerin kullanıldığı görülmektedir. Bu yöntemler, kredi risk yönetiminden tarımsal üretim ve imalat sektörlerine kadar geniş bir uygulama alanında önemli bulgular ortaya koymaktadır.

Yapay zekâ temelli yöntemlerin kredi risk yönetimindeki etkinliği, Budak ve Erpolat (2012) tarafından yapay sinir ağları (YSA) modelleri kullanılarak gösterilmiştir. IBM SPSS aracılığıyla yapılan analizlerde, bireylerin kredi ödeme düzenliliklerinin yüksek doğrulukla tahmin edildiği ve bu yöntemlerin lojistik regresyona kıyasla alternatif çözümler sunduğu vurgulanmıştır. Kavcıoğlu (2019) ise YSA ve lojistik regresyon tabanlı kredi skorumla modellerini karşılaştırarak, makine öğrenmesinin bazı veri setlerinde daha başarılı sonuçlar verdiğini, ancak örneklem dışı analizlerde lojistik regresyonun üstünlük sağlayabildiğini ortaya koymuştur.

Ertuğrul ve Özçil (2017), yapay sinir ağları ile VAR modellerini karşılaştırmış ve yapay zekâ temelli yöntemlerin hata ölçütleri (MAE ve MAPE) açısından üstün olduğunu göstermiştir. Demirbulut vd. (2017) ise kredi riski analizinde kullanılan çeşitli algoritmaları (KNN, C4.5, lojistik regresyon, SVM, Probit regresyon vb.) kıyaslamış ve veri setine uygun yöntem seçiminin performans üzerinde kritik bir etki yarattığını belirtmiştir. Bu çalışmalar, AIXT'nin kredi riski yönetiminde esneklik ve doğruluk sağladığını açıkça göstermektedir.

Tigrak vd. (2020) tarafından yapılan bir başka çalışmada, büyük veri analizi platformlarında makine öğrenmesi modelleri uygulanarak kredi talebi tahmini yapılmıştır. Çalışmada, çok node'lu Spark kümeleri kullanılmış ve makine öğrenmesinin ölçeklenebilir yapısının bankacılık sektöründeki etkileri vurgulanmıştır. Bu bulgular, AIXT'nin büyük veri işleme kapasitesini kredi tahmininde nasıl optimize edebileceğini göstermektedir.

Kredi yönetiminin tarım ve imalat gibi sektörlerdeki etkileri literatürde detaylı bir şekilde ele alınmıştır. Duman ve Türkmen (2023), imalat sektöründe kredi riski analizinde finansal göstergelerin (duran varlık payı, ticari borç oranı gibi) önemli olduğunu ve işletme performansının da dikkate alınması gerektiğini vurgulamıştır. Benzer şekilde, Kırca vd. (2022), 2600 acenteyi analiz ederek risk seviyelerine göre gruplandırma yapmış ve acenteler bazında risk yönetiminin önemini ortaya koymuştur.

Tarım sektörü bağlamında, Yıldız ve Oğuzhan (2007), Türkiye'deki tarımsal kredilerin faiz oranlarından bağımsız olarak üretimi artırdığını VAR modeli ile göstermiştir. Saleem ve Jan (2011), DIK bölgesindeki tarımsal kredilerin (tohum, gübre, sulama vb.) tarımsal GSYİH üzerindeki etkisini analiz etmiş ve bu kredilerin güçlü bir istatistiksel anlamlılık taşıdığını ortaya koymuştur. Obilor (2013), Nijerya'da tarımsal kredi garanti fonlarının verimlilik üzerindeki olumlu etkisini analiz etmiş ve uygun kredi mekanizmalarının tarımsal kalkınmayı desteklediğini belirtmiştir.

Koç vd. (2019), mekânsal panel analiz kullanarak devlet sübvansiyonları ile tarımsal kredilerin hektar başına katma değer üzerindeki etkilerini değerlendirmiş ve kredilerin olumlu etkisine rağmen sübvansiyonların karmaşık bir sonuç yarattığını bulmuştur. Bahşi ve Çetin (2020), Ziraat Bankası kredilerinin tarımsal üretim üzerindeki etkisini incelerken, kredi vadesinin üretim değerine katkıda daha belirleyici olduğunu göstermiştir. Kaya ve Kadanalı (2022) ise, tarımsal krediler ile tarımsal üretim arasında pozitif bir ilişki olduğunu ve bu etkinin özellikle kalkınma ve katılım bankaları aracılığıyla güçlendiğini ortaya koymuştur.

Sevinç (2021), Türkiye'de enflasyon, ekonomik büyüme ve işsizlik oranlarının kredi portföyleri üzerindeki etkilerini Toda-Yamamoto nedensellik testi ve ARDL modeliyle analiz etmiştir. Çalışmada, enflasyon ve büyümenin takipteki kredileri azalttığı, işsizliğin ise çift

yönlü nedensellik ilişkisi oluşturduğu bulunmuştur. Işık vd. (2015), döviz kuru ve ithal mal fiyatlarındaki değişimlerin kredi politikalarına dolaylı etkilerini analiz etmiş ve ithalat kanalıyla enflasyonun kredi portföylerini etkilediğini göstermiştir.

Genel olarak, yapay zekâ ve ileri analitik yöntemlerin (AIXT) kredi riski analizi, kredi tahmini ve sektörel etkilerin değerlendirilmesinde sunduğu esneklik ve doğruluk, bu alandaki literatürde giderek daha fazla kabul görmektedir. Çalışmalar, kredi yönetiminin ekonomik büyüme, sektörel verimlilik ve risk azaltma üzerindeki etkilerini anlamada AIXT'nin vazgeçilmez bir araç haline geldiğini göstermektedir. Gelecekteki araştırmalar, disiplinler arası yaklaşımlar ve daha kapsamlı veri analitiği ile bu bulguları genişletebilir.

Literatürdeki çalışmalar, kredi riskinin tahmini, kredi politikalarının sektörler üzerindeki etkileri ve krediye bağlı üretim ve verimlilik artışı konularında çeşitli yaklaşımlar sunmaktadır. Yapay sinir ağları, lojistik regresyon, makine öğrenmesi teknikleri, VAR modelleri, ARDL, TODA-Yamamoto nedensellik testi, mekânsal panel analizler gibi farklı yöntemler kullanılarak, kredi riskinin yönetiminden tarım ve imalat sektörlerindeki üretim artışına, makroekonomik göstergelerin kredilerle etkileşiminden bankacılık sektöründeki takipteki kredilere kadar geniş bir yelpazede bulgular elde edilmiştir. Bu araştırmalar, bir yandan banka ve finans kurumlarının kredi kararlarına dayalı riskleri minimize etmesine katkı sağlarken, diğer yandan tarım gibi kritik sektörlerde finansman yoluyla üretim artışının sağlanabileceğini göstermektedir. Sonuç itibarıyla, kredilerin ve kredi politikalarının etkin yönetimi hem finansal istikrarın korunmasında hem de sektörel büyüme, tarımsal verimlilik, ekonomik kalkınma ve toplumsal refah hedeflerinin gerçekleştirilmesinde kilit rol oynamaktadır.

İKİNCİ BÖLÜM

2. YÖNTEM

2.1. MAKİNE ÖĞRENMESİ YÖNTEMLERİ

Makine öğrenmesi, bilgisayarların gerçekleşmiş olaylardan bilgi edinerek gelecekte benzer olaylar hakkında tahminlerde bulunabilmesini ve sorunlara çözümler üretebilmesini sağlayan yöntemler topluluğudur (Öztemel, 2006). Büyük veri analizi alanında, makine öğrenmesi yöntemleri sıklıkla kullanılmaktadır. Bu yöntemler, büyük ölçekli veri setlerinde tahminler yapmak, verileri gruplandırmak ve sınıflandırmak gibi görevleri yerine getirmede etkili araçlardır. Kullanılan başlıca makine öğrenmesi algoritmaları arasında Gauss Süreç Regresyonu (GPR), Yapay Sinir Ağları (YSA), Destek Vektör Regresyonu (SVR), Karar Ağaçları ve Topluluk Öğrenme Yöntemleri (Ensemble Learning) gibi yöntemler bulunmaktadır. Bu algoritmalar, öğrenme yaklaşımlarına göre denetimli, yarı denetimli, denetimsiz ve pekiştirmeli öğrenme olmak üzere dört ana kategoriye ayrılmaktadır (Kaynar vd., 2018).

Çalışmanın bu bölümünde makine öğrenmesi algoritmalarına ait bilgilere yer verilerek yapılan araştırmanın dayandığı kuramsal çerçeve ve yapılan araştırmayla benzerlik gösteren daha önceden yapılmış çalışmalara yer verilmiştir.

2.1.1. Denetimli Makine Öğrenmesi

Denetimli öğrenme, eğitim ve test veri setlerinin sisteme yüklenmesi ve her bir veri noktasına uygun etiketlerin atanmasıyla gerçekleştirilen bir makine öğrenmesi yöntemidir. Bu yaklaşım, giriş verileri ile beklenen çıktılar arasındaki ilişkiyi modellemeyi ve bu sayede bilinmeyen veriler için doğru tahminler yapmayı amaçlamaktadır. Denetimli öğrenme, sınıflandırma ve regresyon gibi problemlerde kullanılmakta ve veri kümesindeki bilinen sonuçlardan öğrenerek, bilinmeyen veri noktaları üzerinde tahmin yapma yeteneğine odaklanmaktadır. Bu yöntem, geliştirilen algoritmanın veri setinden çıkarılan bilgileri etkin bir şekilde kullanarak yüksek doğruluk oranıyla sonuçlar üretmesini sağlamaktadır (Aydın & Özkul, 2015:38).

2.1.2. Denetimsiz Makine Öğrenmesi

Denetimsiz öğrenme, etiketlenmemiş veri setleri üzerinde çalışılarak verideki gizli yapıları veya örüntüleri ortaya çıkarmayı amaçlayan bir öğrenme yöntemidir. Bu yaklaşım, etiketli veri gereksinimi olmadığı için özellikle büyük miktarda etiketsiz veri ile çalışılan durumlarda önemli bir avantaj sunmaktadır. Bu veriler eğitim sürecinde kullanılmaktadır ve

sistemden beklenen sonuçlar önceden bilinmemektedir. Sonuçlar eğitim ve izleme dışında üretilmektedir. Bu model yanıt odaklı değildir ve örüntüleri kendi başına bulmak için tasarlanmıştır. Denetimsiz öğrenme, genellikle veri madenciliği, boyut indirgeme, kümeleme ve anomali tespiti gibi uygulamalarda kullanılmaktadır (Monkeylearn, 2021).

2.1.3. Yarı Denetimli Makine Öğrenmesi

Yarı denetimli öğrenme, etiketli ve etiketsiz veri kümelerinin birlikte kullanıldığı hibrit bir öğrenme yöntemidir. Bu yaklaşım, etiketlenmiş veri miktarının sınırlı, ancak etiketsiz veri miktarının oldukça fazla olduğu durumlarda, veri kümesindeki bilgilerden maksimum fayda sağlamak amacıyla geliştirilmiştir. Yöntemin temel amacı, sınırlı sayıdaki etiketli veriden çıkarılan bilginin, etiketsiz veri üzerinde genelleştirilmesini sağlayarak daha yüksek doğruluk oranlarıyla tahminler gerçekleştirmektir. Yarı denetimli öğrenme, denetimli öğrenmenin güçlü yönleri ile denetimsiz öğrenmenin veri içindeki yapısal örüntüleri keşfetme yeteneğini birleştirerek, veri analitiğinde daha etkili bir çözüm sunmak amacıyla ortaya konulmuştur. Bu yöntem, etiketsiz verinin büyük hacmiyle birlikte kullanılabilen denetim mekanizmaları sayesinde, sınırlı veri ile bile yüksek performanslı modellerin geliştirilmesine olanak tanımaktadır (Reddy vd., 2018).

2.1.4. Pekiştirmeli Makine Öğrenmesi

Pekiştirmeli öğrenme, makine öğrenmesinin, bir aracı (agent) ve çevre (environment) arasındaki etkileşime dayalı bir öğrenme paradigmalarından biridir. Bu yöntemde, bir aracı, çevreye eylemler (actions) uygulayarak geri bildirim (ödül veya ceza) alır ve bu geri bildirimlerden öğrenerek bir hedefe ulaşmayı amaçlamaktadır. Pekiştirmeli öğrenme, karar verme problemlerinde etkili bir çözüm sunar ve karmaşık, dinamik sistemlerde etkili politikalar geliştirmek için kullanılmaktadır. "Deneme-yanılma" yoluyla öğrenme temelinde bir süreç yapılandırarak; çevreyi keşfederek farklı eylemler denemekte ve bu eylemlerin sonucunda aldığı ödülleri temel alan bir politika geliştirmektedir. Bu sürecin amacı, uzun vadede ödül toplamını maksimize edecek bir politika öğrenmektir (Matsuo vd., 2022).

2.2. MAKİNE ÖĞRENMESİ ALGORİTMALARI

Makine öğrenmesi, bilgisayarların benzer olaylara ilişkin çıkarımlar yapabilmesini ve çeşitli problemlere çözümler üretebilmesini sağlayan bir alandır. Makine öğrenmesi, örüntü tanıma, veri analizi ve tahmin yapma yetenekleriyle öne çıkarak, algoritmaların veriden öğrenmesine ve veri ile desteklenen kararlar almasına olanak tanıyan bir bilim dalı olarak kabul edilmektedir (Bilgin, 2018; Öztemel, 2003). Aşağıda, bu çalışmada uygulanacak makine öğrenmesi yöntemlerinin teorik temelleri ayrıntılı olarak sunulmuştur.

2.2.1. Gauss Süreç Regresyonu (GPR)

Gauss Süreç Regresyonu (GPR), makine öğrenmesinde kullanılan ve gözlemler arasındaki belirsizlikleri modellemek için esnek bir yöntem sunan, olasılıksal bir yaklaşımdır. GPR, özellikle küçük veya orta boyutlu veri kümelerinde doğruluğu artırmak amacıyla tercih edilmektedir. Bu yöntem, veri noktaları arasındaki ilişkiyi modellemek için "gauss süreci" adı verilen bir olasılık sürecini kullanmakta ve her bir tahminin etrafında bir belirsizlik (varyans) tahmini sunmaktadır. Bu özellik, Gauss Süreç Regresyonu'nu sadece tahmin yapmada değil, aynı zamanda modelin tahminlerindeki güven seviyesini değerlendirmede de etkili olmasını sağlamaktadır. GPR, veriyi doğrudan bir fonksiyon şeklinde modellemek yerine, her bir veri noktası için bir dağılım oluşturmaktadır. Bu dağılımlar, verilerin birbirine olan yakınlığına ve benzerliğine bağlı olarak ilişkilendirilmekte ve bu ilişkilendirmede çekirdek fonksiyonları (kernel functions) kullanılmaktadır. Çekirdek fonksiyonlarının seçimi, modelin başarımında kritik bir rol oynamaktadır. Tablo 1'de, genellikle GPR ile kullanılan çekirdek fonksiyonları verilmiştir.

Tablo 1: GPR Kernel Fonksiyonlarının Matematiksel İfadeleri

Kernel Fonksiyonu	Matematiksel İfade
Sabit	$k = \sigma_0^2$
Doğrusal	$k_{lin}(x, x') = x^T x' + c$
Polinomal	$k_{poly}(x, x') = (x^T x' + \sigma_0^2)^p$
Kare Üstel	$k_{SE}(r) = \exp\left(-\frac{r^2}{2l^2}\right)$
Rasyonel Kare	$k_{RQ}(r) = \left(1 + \frac{r^2}{2\alpha l^2}\right)^{-\alpha}$
Kuvvet	$k_p(r) = -r^p$
Matern-3	$k(x, x') = \sigma_f^2 \left(1 + \frac{\sqrt{3}r}{l}\right) \exp\left(-\frac{\sqrt{3}r}{l}\right)$

Gauss Süreç Regresyonu'nun en belirgin avantajlarından biri, parametrik olmayan bir yapıya sahip olmasıdır; bu yapı modelin veriye bağımlı dinamik olarak değişebilmesini sağlamaktadır. Parametrik olmaması, özellikle doğrusal olmayan veri yapılarında modelin uyum kapasitesini artırarak üstün performans sergilemesine olanak tanımaktadır. Ek olarak, parametrik bir yapıya bağlı olmamak; her yeni gözlemle birlikte güncellenebilme yeteneğini desteklemekte ve bu durum da tahminlerin doğruluğunu artırmaktadır. Fakat, Gauss Süreç Regresyonu'nun büyük veri setleri üzerinde uygulanması hesaplama açısından maliyetli olabilir. Çünkü GPR, tahminleri yaparken gözlem sayısının karesi ile orantılı bir hesaplama yükü oluşturmaktadır. Bu nedenle, büyük veri setlerinde GPR'yi kullanmak için seyrekleştirme (sparse approximation) ve azaltılmış veri kümeleri gibi yöntemler tercih edilmektedir.

Gauss Süreç Regresyonu (GPR), belirsizliklerin modellenmesi ve yüksek esneklik sunması nedeniyle veri analizinde etkili bir yöntem olarak dikkat çekmektedir. Özellikle

belirsizlik tahminlerinin kritik önem taşıdığı uygulamalarda, GPR geleneksel regresyon tekniklerine göre daha güvenilir ve anlamlı sonuçlar sağlayabileceği saptanmıştır. Gauss Süreci, iki temel bileşen olan ortalama fonksiyonu ve çekirdek fonksiyonu ile tanımlanır. Ortalama fonksiyonu, verinin genel eğilimini yansıtırken, çekirdek fonksiyonu veri noktaları arasındaki ilişkileri veya benzerlikleri ifade etmektedir. Bu iki fonksiyon, modelin temel yapısını oluşturmakta ve GPR'nin hem esnek hem de yüksek doğruluğa sahip bir modelleme yöntemi olmasını sağlamaktadır. Zhang vd. (2016) tarafından verilen denklem (1)'e göre, Gauss Süreci fonksiyonu bu bileşenlerle tanımlanmaktadır.

$$f(\mathbf{x}) \sim GP(\mu(\mathbf{x}), k(\mathbf{x}, \mathbf{x}')) \quad (1)$$

Kernel fonksiyonu ise hiperparametreleri içermektedir. GPR orijinal zaman serisini oluşturan $S = \{(\mathbf{x}_i, y_i) \mid i = 1, 2, \dots, M\}$ bir eğitim setine sahiptir, burada $\mathbf{x}_i = [y_{t-1}, y_{t-(i+1)}, \dots, y_{t-(i+p-1)}]^T$ girişleri temsil etmektedir ve çıkışlar vektörü aşağıdaki gibi tanımlanır.

$$y = f(\mathbf{x}) + \epsilon \quad (2)$$

Burada ϵ bir gürültü söz konusudur. Olasılık Denklemi (3)'te görülmektedir.

$$p(\mathbf{y} \mid \mathbf{f}) = N(\mathbf{y} \mid \mathbf{f}, \sigma_n^2 \mathbf{I}) \quad (3)$$

Burada $\mathbf{y} = [y_1, y_2, \dots, y_M]^T$, $\mathbf{f} = [f(\mathbf{x}_1), f(\mathbf{x}_2), \dots, f(\mathbf{x}_M)]^T$ ve $M \times M$ birim matrisi $\mathbf{I}$ olarak gösterilir. GP tanımına göre, $p(\mathbf{f})$ 'nin ortalaması sıfırdır, bir Kernel fonksiyonu bir K matrisi tarafından belirlenir,

$$p(\mathbf{f}) = N(\mathbf{f} \mid \mathbf{0}, K) \quad (4)$$

Burada $K_{ij} = k(\mathbf{x}_i, \mathbf{x}_j)$. Eşitlik (3) ve Eşitlik (4) analiz edilirse her iki denklem de Gauss dağılımını takip etmektedir. Böylece, y aşağıdaki gibi ifade edilir,

$$p(\mathbf{y}) = \int p(\mathbf{y} \mid \mathbf{f}) p(\mathbf{f}) d\mathbf{f} = N(\mathbf{f} \mid \mathbf{0}, K_y) \quad (5)$$

Burada $K_y = K + \sigma_n^2 I$

yeni bir x_* , girdisi ile y elde etmek için $y_1, y_2, \dots, y_m, y_*$ üzerindeki ortak dağılım

$$\begin{bmatrix} y \\ y_* \end{bmatrix} = \begin{bmatrix} f \\ f_* \end{bmatrix} + \begin{bmatrix} \epsilon \\ \epsilon_* \end{bmatrix} \sim N \left(\mathbf{0}, \begin{bmatrix} K_y & \mathbf{k}_* \\ \mathbf{k}_*^T & k_{**} + \sigma_n^2 \end{bmatrix} \right) \quad (6)$$

ile belirlenir. Burada $(\mathbf{x}_*)$ girişleri için gizli fonksiyon $f_* = f(\mathbf{x}_*)$ ve ϵ_* ersatz gürültüsüdür; $\mathbf{k}_* = [k(\mathbf{x}_*, \mathbf{x}_1), \dots, k(\mathbf{x}_*, \mathbf{x}_M)]^T$ ve $k_{**} = k(\mathbf{x}_*, \mathbf{x}_*)$. $P(y_* | y)$ Gauss dağılımıdır. Fonksiyonun ortalaması ve kovaryansı Eşitlik (7) ve Eşitlik (8)'de verilmiştir.

$$\mu(\mathbf{x}_*) = \mathbf{k}_*^T K_y^{-1} \quad (7)$$

$$\sigma^2(\mathbf{x}_*) = k_{**} - \mathbf{k}_*^T K_y^{-1} \mathbf{k}_* + \sigma_n^2 \quad (8)$$

GPR, çıktı fonksiyonları üzerinde önceki bir dağılımın kovaryansını tanımlamak için Kernel fonksiyonunu kullanılmaktadır (Zhang vd., 2016).

2.2.2. Destek Vektör Regresyonu (SVR)

Destek Vektör Makineleri (SVM), sınıflandırma ve regresyon problemlerinde yaygın olarak kullanılan güçlü bir makine öğrenmesi yöntemidir. İlk olarak 1990'lı yıllarda Vladimir Vapnik ve ekibi tarafından geliştirilen bu yöntem (Gülyüz, 2020) yüksek boyutlu veri kümelerinde etkili sonuçlar sunmasıyla dikkat çekmektedir. SVM, veri noktalarını sınıflandırırken karar sınırlarını maksimize ederek optimal bir hiper düzlem oluşturmaktadır. Bu hiper düzlem, sınıflar arasındaki ayrımı en iyi şekilde temsil etmekte ve sınıflandırma hatalarını en aza indirmektedir. Destek Vektör Makinelerinin temel amacı, veriyi iki sınıfa ayırırken en geniş marjı sağlayacak düzlemi belirlemektir. Bu sayede, model hem eğitim verisinde hem de yeni verilerde yüksek bir doğruluk oranıyla çalışmaktadır. SVM, doğrusal ayrılabilir olmayan veri kümelerinde de başarılı performans gösterebilir; bu durumda çekirdek fonksiyonları (Kernel Functions) kullanılarak veriler daha yüksek boyutlara taşınır ve ayrılabilir hale getirilir. Çekirdek fonksiyonları sayesinde karmaşık yapılar, doğrusal olarak ayrılabilir hale gelir ve sınıflandırma işlemi gerçekleştirilir.

SVM, özellikle sınıflar arası ilişkilerin ve değişkenler arasındaki karmaşık etkileşimlerin analiz edilmesi gereken veri madenciliği projelerinde tercih edilmektedir. Yüksek boyutlu verilerde güçlü performansı ve genelleme yeteneği, onu biyoinformatik, görüntü işleme, doğal dil işleme ve finans gibi çeşitli alanlarda kullanılır hale getirmiştir.

Bununla birlikte, SVM'nin büyük veri kümeleri için hesaplama yükünün yüksek olabileceği ve model parametrelerinin optimizasyonunun dikkatle yapılması gerektiği unutulmamalıdır. Sınıflandırma problemlerinde, SVM'nin temel amacı, verileri doğru bir şekilde sınıflandırmak için maksimum marjlı bir hiper düzlem bulmaktır. Diğer doğrusal öğrenme makineleriyle aynı prensiple çalışan SVM, yapısal risk minimizasyonu ile test edilecek veriler için kullanılmaktadır. Bu yöntem, büyük veri kümelerinde etkili sınıflandırma sonuçları elde etmek için kullanılmaktadır. SVM'nin avantajı, yüksek boyutlu verileri işlerken doğruluk oranını artırabilmesi ve aşırı öğrenmeyi azaltmasıdır. SVM, özellik çıkarma ve veri ön işleme adımlarıyla birlikte kullanılarak daha iyi sonuçlar elde edilebilir (Avşar, 2009). Ancak, regresyon problemlerinde de benzer prensiplere dayanarak kullanılabilir ve bu durumda Destek Vektör Regresyonu (SVR) olarak adlandırılmaktadır. SVR, veriler arasındaki doğrusal olmayan ilişkileri modellemek için kernel fonksiyonlarını kullanarak yüksek boyutlu uzaya dönüşüm sağlamak ve doğrusal olmayan regresyon problemlerinde başarılı sonuçlar vermektedir. SVM'nin sınıflandırmada sınır çizgisi (hyperplane) oluşturması gibi, SVR'de de hedef, belirli bir hata toleransı (epsilon) içerisinde tahminler yaparak en uygun regresyon hiperdüzlemini belirlemektir. SVR'nin esnek yapısı ve kernel trick sayesinde, karmaşık ve doğrusal olmayan ilişkilerin bulunduğu veri setlerinde yüksek genelleme kapasitesi sunabilmektedir. Bu çalışmada, sınıflandırma amaçlı SVM modelinden regresyon amaçlı SVR modeline geçiş, tarım kredileri tahmini gibi sürekli hedef değişken içeren bir problem için uygun çözüm sağlamaktadır.

Ayrıca, hesaplama karmaşıklığı SVR modelindeki girdi değişkenlerinin hacmine bağlı değildir. Bu özellik SVR modelini diğer yapay zekâ tabanlı tahmin modellerine göre daha avantajlı hale getirmektedir. Kernel fonksiyonu, doğrusal olmayan fonksiyonu Kernel aracılığıyla doğrusal bir fonksiyona dönüştürmektedir. Kernel fonksiyonları doğrusal olmayan problemlerin çözümünü kolaylaştırır. SVR mimarisi, Eşitlik (9)'da görüldüğü gibi aşağıdaki gibi formüle edilir, amaç fonksiyonu ve kısıtlamaları içermektedir.

$$\begin{aligned} \text{maximize} \quad & \begin{cases} \frac{1}{2} \sum_{i=1}^l (\alpha_i - \alpha_i^*) (\alpha_i - \alpha_i^*) K(x_i, x_j) \\ - \epsilon \sum_{i=1}^l (\alpha_i + \alpha_i^*) + \sum_{i=1}^l y_i (\alpha_i - \alpha_i^*) \end{cases} \\ \text{s.t} \quad & \begin{cases} \sum_{i=1}^l (\alpha_i - \alpha_i^*) = 0 \text{ and } \alpha_i, \alpha_i^* \in [0, C] \\ 0 \leq \alpha_i, \alpha_i^* \leq \frac{C}{l} \\ i = 1, 2, \dots, l \end{cases} \end{aligned} \quad (9)$$

Eşitlik (9)'da, x_i kullanılan verileri, 1 veri örneğinin boyutunu, C ceza katsayısını, ϵ verilerin ceza boyutunu ve $K(x_i, x_j)$ çekirdek fonksiyonunu temsil etmektedir. Optimum çözümü elde etmek için $\alpha = [\alpha_1, \alpha_1^*, \dots, \alpha_l, \alpha_l^*]^T$ ayarlanır ve destek vektör regresyonu Eşitlik (10)'da gösterilmektedir.

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x_i - x_j) + b^* \quad (10)$$

Eğer $(\alpha_i - \alpha_i^*)$ sıfıra eşit değilse, uygun örnek x_i bir destek vektörü olacaktır (Quan vd., 2020).

Tablo 2, GPR ve SVR ile yaygın olarak kullanılan bazı çekirdek fonksiyonlarını göstermektedir.

Tablo 2: SVR Çekirdek Fonksiyonlarının Matematiksel İfadeleri

Kernel Fonksiyonu	Matematiksel İfade
Doğrusal	$K(x_i, x_j) = (x_i, x_j)$
Polinomal	$K(x_i, x_j) = (\langle x_i, x_j \rangle + 1)^d$
Gauss	$K(x_i, x_j) = e^{-\frac{\ x_i - x_j\ ^2}{2\gamma^2}}$
Sigmoid	$K(x_i, x_j) = \tanh(\gamma \langle x_i, x_j \rangle + 1)^d$

* Burada $r = \|x - x'\|$ x ile x' arasındaki aralıktır.

SVM'ler, yüz algılama, metin ve hiper metin sınıflandırma, görüntü sınıflandırma, biyoinformatik, protein çaprazlama, uzaktan homoloji tespiti, el yazısı tanıma, jeoloji ve çevre bilimleri, genelleştirilmiş öngörücü kontrol uygulamaları gibi birçok alanda kullanılmaktadır. Bu uygulamalar, SVM'lerin literatürde sıkça kullanılan örüntüler olduğunu göstermektedir. Özellikle, SVM'lerin yüz algılama, metin sınıflandırma ve görüntü sınıflandırma gibi görsel işleme alanlarında etkili olduğu görülmektedir. Ayrıca biyoinformatikte protein çaprazlama ve uzaktan homoloji tespiti, el yazısı tanıma, jeoloji ve çevre bilimlerindeki uygulamalarda da SVM'ler yaygın olarak kullanılmaktadır (Gour, 2019).

Sonuç olarak, Destek Vektör Makineleri, sınıflandırma ve regresyon görevlerinde etkin bir çözüm sunarak makine öğrenmesi ve veri madenciliği alanında önemli bir yer edinmiştir. Bu yöntemin doğru parametrelerle uygulanması, karmaşık veri yapılarının başarılı bir şekilde analiz edilmesine olanak tanımaktadır.

2.2.3. Karar Ağaçları (DT)

Karar ağaçları, sınıflandırma ve regresyon problem yapılarının her ikisinde de kullanılan hem açıklanabilirliği hem de hesaplama verimliliği nedeniyle makine öğrenmesi alanında önemli yöntemlerden biridir. Bu yöntem, veri setini belirli kriterlere göre dallara ayırarak hedef değişkene yönelik tahmin veya sınıflandırma işlemini gerçekleştiren hiyerarşik bir yapıya dayanmaktadır. Karar ağaçlarının temel çalışma prensibi, veri集中的 bağımsız değişkenleri kullanarak, bağımlı değişkenin belirli bir değere veya sınıfa ait olma olasılığını en üst düzeye çıkaracak şekilde veri bölünmelerini optimize etmektir. Bölünme kriterleri genellikle bilgi kazancı, Gini indeksi veya varyans azaltımı gibi metriklerle dayalı olarak hesaplanmaktadır (Sharma & Kumar, 2016).

Karar ağaçları, bir karara ulaşmak için kullanılan ağaç benzeri bir yapı oluşturmaktadır. Bu yapıda, dal, yaprak ve kök gibi terimler kullanılmaktadır. Karar düğümleri, sınıflandırma veya tahmin etme amaçlarıyla kullanılır ve en az iki dala ayrılmaktadır. Yaprak düğümleri ise kararları saklamayı sağlamaktadır. Ağacın tepesindeki düğüm kök olarak adlandırılır ve belirli bir yol izleyerek yaprak düğümlerine ulaşmak için kullanılmaktadır. Karar ağaçlarının oluşturulmasında, farklı bölünme kriterleri ve yöntemler kullanan çeşitli algoritmalar mevcuttur. Örneğin, ID3, C4.5, C5.0, CART, CHAID ve QUEST algoritmaları, karar ağaçlarının oluşturulmasında kullanılan popüler yöntemlerdir. Bu algoritmalar, veri集中的 değişkenlerin hedef değişken üzerindeki etkisini optimize etmek için farklı ölçütlere dayanmaktadırlar. ID3 algoritması bilgi kazancını, C4.5 ve C5.0 algoritmaları bilgi kazancının normalleştirilmiş bir formu olan kazanç oranını, CART algoritması ise Gini indeksi veya varyans azaltımını kullanmaktadır. CHAID ve QUEST ise kategorik ve sürekli veriler üzerinde farklı istatistiksel yöntemlerle çalışarak karar ağaçlarını optimize etmektedirler (Kotsiantis, 2013).

Sonuç olarak, karar ağacı modellerinin etkili bir şekilde kullanılabilmesi için dallanma sürecinin optimal bir noktada durdurulması kritik öneme sahiptir. Dallanmanın erken durdurulması, modelin genelleme yeteneğini kısıtlayarak yetersiz öğrenmeye yol açabileceği gibi, aşırı dallanma durumunda modelin işlem maliyeti artabilecek ve genelleme yeteneği zarar görebilecektir. Bu dengeyi sağlamak için, doğrulama veri setleri üzerinde değerlendirme yapılarak dallanma sürecinin optimize edilmesi gerekmektedir. Böylece, karar ağacı modeli, hem yüksek doğruluğa sahip sonuçlar üretebilecek hem de işlem verimliliğini koruyarak hedeflenen performansa ulaşabilecektir (Şekeroğlu, 2010).

Karar ağaçları oluşturulurken, doğru bölünme noktalarını belirlemek için kullanılan ölçütler, modelin doğruluğunu ve genelleme yeteneğini doğrudan etkilemektedirler. Bu

bağlamda, Entropi, Bilgi Kazancı, Gini Safsızlığı, Regresyon Ağacı ve Ortalama Kare Hata, bölünme kararlarında temel alınan önemli kriterlerdir. Entropi, bir düğümdeki veri setinin homojenlik düzeyini ölçmek için kullanılır ve düşük entropi, daha saf bir düğüm anlamına gelmektedir. Bilgi kazancı ise, bir özelliğin hedef değişken hakkında ne kadar bilgi sağladığını belirlemekte ve karar ağacında daha yüksek bilgi kazancı sağlayan bölmeler tercih edilmektedir. Gini Safsızlığı, veri noktalarının farklı sınıflara ait olma olasılığını ölçen bir diğer önemli kriterdir ve genellikle sınıflandırma problemlerinde kullanılmaktadır. Regresyon ağaçlarında, bölünme noktaları belirlenirken hatayı minimize etmek amacıyla ortalama kare hata gibi metrikler tercih edilmektedir. Bu ölçütler, karar ağacının farklı veri yapılarında etkili bir şekilde çalışmasını sağlamak için geliştirilmiş olup, sınıflandırma ve tahmin problemlerinde yaygın olarak uygulanmaktadır (Quinlan, 1986).

2.2.3.1. Entropi (Entropy) ve bilgi kazancı (information gain)

Entropi, bir veri kümesindeki belirsizliği ölçen bir kavramdır. Shannon'un Entropi formülü şu şekildedir:

$$H(D) = - \sum_{i=1}^k p_i \log_2(p_i) \quad (11)$$

Bu denkleme göre, p_i , her bir sınıfın (etiketin) veri kümesindeki olasılıklarını belirtir. Bu, karar ağacında bir düğümdeki veri kümesinin homojenliğini değerlendirmek için kullanılmaktadır. k , sınıf sayısını ifade etmektedir (Shannon, 1948).

2.2.3.2. Bilgi kazancı

Bir özelliğin kullanılarak yapılan bir bölme sonrasında elde edilen bilgi kazancı şu şekilde hesaplanır:

$$IG(D, A) = H(D) - \sum_{v \in \text{Values}(A)} \frac{|D_v|}{|D|} H(D_v) \quad (12)$$

Burada:

- D : Orijinal veri kümesi.
- A : Seçilen özellik,
- $v \in \text{Values}(A)$: O özelliğin aldığı olası değerler.
- D_v : Özelliğin v değerine sahip alt kümesi.

Bu formül, bir özelliğin hedef değişken hakkında ne kadar bilgi sağladığını belirler ve bu nedenle daha yüksek bilgi kazancı sağlayan bölmeler tercih edilmektedir (Quinlan, 1986).

2.2.3.3. Gini impurity (Gini safsızlığı)

Gini Safsızlığı karar ağaçlarında, bir düğümün safsızlığını (heterojenliğini) ölçmek için kullanılan bir metriktir. Gini safsızlığı, bir veri kümesindeki örneklerin farklı sınıflara ait olma olasılıklarının bir ölçüsüdür. Bu kriter, aşağıdaki gibi hesaplanmaktadır.

$$Gini(D) = 1 - \sum_{i=1}^k p_i^2 \quad (13)$$

Burada:

1. p_i : Her sınıfın veri kümesindeki olasılığını temsil etmektedir.
2. k : Sınıf sayısını belirtmektedir.

Eğer bir düğümdeki tüm örnekler tek bir sınıfa aitse, Gini safsızlığı sıfır olur, bu da düğümün tamamen saf olduğunu göstermektedir. Ancak düğümdeki sınıflar karışık ise, Gini safsızlığı artmaktadır (Breiman vd.,1984).

2.2.3.4. Regresyon ağacı ve ortalama kare hata

Regresyon ağacı, sürekli bir hedef değişkenin değerlerini tahmin etmek için kullanılan bir karar ağacı yöntemidir. Bu yöntem, veri setini belirli kurallara göre dallara ayırarak, her bir yaprak düğümde hedef değişkenin tahminini yapmaktadır. Regresyon ağacı, sınıflandırma ağaçlarından farklı olarak, hedef değişkenin bir kategorik değil, sürekli bir değişken olduğu durumlarda kullanılmaktadır. Bölünme işlemi sırasında, veri setindeki varyansı en aza indirecek şekilde bölünme noktaları seçilmelidir. Regresyon ağaçlarında, modelin performansını değerlendirmek ve en uygun bölünme noktalarını belirlemek için ortalama kare hata (MSE) metriği sıklıkla kullanılmaktadır. Ortalama kare hata, tahmin edilen değerler ile gerçek değerler arasındaki farkların karelerinin ortalamasını alarak hesaplanmaktadır (Hastie, 2009). Denklem (14)'de MSE'nin matematiksel denklemi görülmektedir.

$$MSE = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (14)$$

Burada:

1. y_i : Gerçek değerler,
2. $\hat{y}_i$: Tahmin edilen değerlerdir.

Regresyon ağaçları, özellikle doğrusal olmayan ve karmaşık ilişkilerin mevcut olduğu veri setleri için oldukça etkili bir modelleme yaklaşımıdır. Bu yöntem, kullanıcı dostu ve kolay yorumlanabilir yapısıyla dikkat çekerken, parametrik bir modele ihtiyaç duymadan farklı veri türleri üzerinde uygulanabilme esnekliği sunmaktadır. Bununla birlikte, aşırı öğrenme (overfitting) durumunda modelin genelleme performansı ciddi şekilde düşebilecektir. Bu nedenle, modelin doğrulama veri setleriyle değerlendirilerek optimize edilmesi ve genelleme kapasitesinin korunması kritik bir gereklilik olarak öne çıkmaktadır (Goodfellow, 2016).

2.2.3.5. Karar ağacı inşası ve optimizasyonu (pruning)

Karar ağacı inşası, verinin yapısına uygun bir model oluşturmayı hedeflerken, modelin genelleme yeteneğini korumak ve aşırı öğrenmeyi (overfitting) önlemek için iyi tasarlanmış bir süreç gerektirmektedir. Bu süreç ağaç inşası ve budama (pruning) olmak üzere ikiye ayrılmaktadır. Ağaç inşası sırasında, veri seti belirli kriterlere göre dallara ayrılarak hedef değişkenle en yüksek ilişkiye sahip bölünmeler seçilmektedir. Ancak, bu aşamada ağacın çok fazla dallanması, modelin eğitim verisine aşırı uyum sağlamasına ve yeni veriler üzerinde düşük performans göstermesine neden olabilmektedir. Bu problemi çözmek için budama teknikleri kullanılmaktadır. Budama, gereksiz veya az katkı sağlayan dalların kaldırılarak ağacın sadeleştirilmesini ve genelleme kapasitesinin artırılmasını sağlamaktadır. Bu süreç hem modelin doğruluğunu hem de işlem verimliliğini optimize etmek için kritik bir adım olarak tanımlanmıştır. Karar ağacı inşası ve budama teknikleri, sınıflandırma ve regresyon problemlerinde etkin bir çözüm sunarak hem teorik hem de pratik uygulamalarda önemli bir yer tutmaktadır (Loh, 2011).

2.2.4. Topluluk Öğrenmeleri (EL)


Ensemble learning – EL (topluluk öğrenmesi), birden fazla makine öğrenmesi modelinin bir araya getirilerek daha yüksek doğruluk ve genelleme yeteneği sağlamak amacıyla kullanılan bir yöntemdir. Temel prensip, tek bir modelin sınırlamalarını aşarak, çeşitli modellerin güçlerini birleştirerek daha sağlam ve güvenilir tahminler elde etmektir. Bu yöntem, özellikle karmaşık veri setleri üzerinde genelleme performansını artırmak ve modelin aşırı öğrenme (overfitting) gibi sorunlarını minimize etmek için sıklıkla tercih edilir. EL'nin temelinde, farklı modellerin tahminlerinden yararlanarak hataları telafi etme prensibi vardır. Bir topluluğun gücü, modellerin bağımsızlığı ve çeşitliliğine bağlıdır; bu nedenle, farklı türde modeller veya aynı modelin farklı varyasyonları birleştirilerek daha etkili sonuçlar elde edilebilmektedir (Rokach, 2010).

EL, üç temel strateji çerçevesinde yapılandırılmaktadır. Bu stratejiler; Bagging, Boosting ve Stacking'dir. Bagging (Bootstrap Aggregating), veri setinin farklı alt kümeleri üzerinde aynı türden modellerin bağımsız olarak eğitilmesini ve elde edilen tahminlerin birleştirilmesini esas almaktadır. Bootstrap yöntemi kullanılarak orijinal veri setinden rastgele örnekler seçilir ve her bir model bu alt veri setleriyle eğitilmektedir. Sınıflandırma problemlerinde çoğunluk oylaması, regresyon problemlerinde ise tahminlerin ortalaması alınarak sonuçlar birleştirilmektedir. Bagging yönteminin en bilinen uygulamalarından biri Random Forest algoritmasıdır. Boosting ise zayıf öğreniciler olarak adlandırılan basit modellerin sıralı bir şekilde eğitilmesi ve her modelin bir önceki modelin hatalarını azaltmaya odaklanması prensibine dayanmaktadır. Bu strateji, model ağırlıklarının hatalara göre dinamik olarak ayarlanmasıyla, önceki tahminlerde yapılan hataların sonraki modeller tarafından düzeltilmesini sağlamaktadır. Bu yöntemin popüler örnekleri arasında AdaBoost, Gradient Boosting ve XGBoost algoritmaları yer almaktadır. Boosting, özellikle karmaşık veri setlerinde yüksek doğruluk oranları sağlayan bir yöntem olarak bilinmektedir. Stacking ise birden fazla modelin tahminlerinin, üst düzey bir meta-model tarafından öğrenilmesini amaçlayan bir yaklaşımdır. Bu yöntemde, farklı modellerin çıktıları birleştirilir ve bu tahminler, meta-model tarafından kullanılarak nihai tahmin üretilmektedir. Logistic regression veya yapay sinir ağları gibi meta-modeller genellikle stacking yönteminde tercih edilmektedir. Bu strateji, farklı türdeki modellerin güçlü yönlerinden yararlanarak daha karmaşık ve genelleştirilebilir sonuçlar üretmektedir. EL bu üç stratejisi hem doğruluğu artırmak hem de genelleme yeteneğini güçlendirmek için yaygın olarak kullanılmaktadır (Friedman, 2001).

2.2.5. Yapay Sinir Ağları (YSA)

Yapay sinir ağı, biyolojik sinir hücreleri (nöron) yapıları dikkate alınıp modellenmiş olan ya da süreç içinde kendisine öğrenme yeteneklerine sahip olan bir algoritmayı ifade etmektedir. Yapay sinir ağı, robot teknolojileri, Tıp, kuvvet sistemi, desen tanıma ya da sinyal işleme ile tahmin ve bilhassa sistem modelleme gibi çok farklı uygulama alanlarında kullanılmaktadır (Dogan & Atik, 2004). Basit bir yapay sinir ağı aşağıdaki tabloda örneklendirilmiştir. Aşağıdaki şekilde görülen yapay sinir ağı modeli, matematiksel bir şekilde aşağıdaki eşitlikteki gibi ifade edilmektedir.

$$u_k = \sum_{j=1}^n w_{kj} x_j \quad (15)$$



Şekil 6: Yapay Sinir Ağı Modeli

Yapay sinir ağı, nöronun birbiri ile bağlantısı sonucuyla bir araya toplanmasından oluşmaktadır (Karahan, 2015). Bununla beraber, kendisine verilmiş olan farklı örnek ya da verilerden çıkarımlar ya da genellemeler yapılarak öğrenilmeye çalışılır ve de böylelikle yeni bilgiler türetilmektedir. Yapay sinir ağı teknikleri, doğrusal olmayan sorunların çözülmesinde kullanılmaktadır. Veriler, test kümeleri ya da eğitim olarak ikiye ayrılmaktadır. Eğitim sürecinin hedefi sinir ağında bulunan ağırlıkları ayarlayıp hata seviyesini minimuma indirmektir. Bu süreç, hedeflenmiş olan çıktı elde edilene kadar sürmektedir. Eğitim işleminin performans seviyesi, eğitim sırasında kullanılmamış olan verilerin sinir ağında test edilmesi ile elde edilmektedir (Tasdemir vd., 2009). Ağın eğitilmesinde, ileri beslemeli geri yayımlı sinir ağı mimarisi oldukça etkili bir konumdadır.

İleri beslenmeli sinir ağı, modelin girdi katmanlarından çıktı katmanlarına doğru tek taraflı ilerlemektedir. İleri beslemeli yapay sinir ağı modeli, öncelik olarak girdi katmanı, sonrasında bir veya iki olarak da gizli katman son olarak çıktı katmanından oluşmaktadır (Hamzaçebi & Kutay, 2004). Ağın eğitimi, her bir katmanda bulunmuş olan nöron arasında ilişkilerin ağırlığının düzenlenmesi ile gerçekleşmektedir. Bu işlem aşağıdaki eşitlikte sunulmuş olan hata fonksiyonu ile gerçekleşmektedir. (d_j hedeflenmiş olan sonuçlar, o_j ;gerçekleşmesi muhtemel sonuç).

$$E^p = \frac{1}{2} \sum_j (d_j^p - o_j^p)^2 \quad (16)$$

Aşağıda bulunan hata fonksiyonu farkı, ağırlığın tekrardan düzeltilmesi amacı ile kullanılmaktadır.

$$\Delta^p w_{ji} = -\eta \cdot \left(\frac{\partial E^p}{\partial w_{ji}} \right) \quad (17)$$

Yukarıda yer alan denklemde η sabiti öğrenme seviyesi için herhangi bir değer atanabilir. Ağırlıkların tekrardan kullanılması için aşağıda yer alan eşitlik kullanılmaktadır.

$$w_{ij}(t+1) \cong w_{ij}(t) + \eta \cdot \delta_j \cdot i_i \quad (18)$$

Yukarıda bulunan denklemde, $w_{ij}(t)$: ağırlık i_i : i düğümünün sonuç değeri ya da δ_j : j düğümünün hata terimini ifade etmektedir. Çıktı katmanında bulunan düğüm için hata: (δ_j) ;

$$\delta_i \cong o_j \cdot (1 - o_j) \cdot (d_j - o_j) \quad (19)$$

Formülü ile hesaplanmaktadır. δ_j Düğümü bir gizli düğüm olmak üzere hataların terimi (δ_j) (Eşitlik 20):

$$\delta_i \cong o_j \cdot (1 - o_j) \cdot \sum_k \delta_k \cdot w_{jk} \quad (20)$$

Ağırlık değişikliği, herhangi bir "moment" terimlerinin (α) eklenmesi ile yenilenmektedir.

$$w_{ij}(t+1) \cong w_{ij}(t) + \eta \cdot (d_j - o_j) \cdot i_i + \alpha \cdot (w_{ij}(t) - w_{ij}(t-1)) \quad (21)$$

2.3. İSTATİSTİKSEL YÖNTEM: ÇOK DEĞİŞKENLİ DOĞRUSAL REGRESYON (MLR)

Çok değişkenli doğrusal regresyon, bir bağımlı değişken ile birden fazla bağımsız değişken arasındaki doğrusal ilişkiyi modellemek amacıyla kullanılan istatistiksel bir yöntemdir. Bu yöntem, özellikle karmaşık veri setlerinde, birden fazla faktörün bir sonuç değişkeni üzerindeki etkilerini aynı anda analiz etmek için güçlü bir araç sunmaktadır. Çok değişkenli doğrusal regresyon, bağımlı değişkenin bağımsız değişkenlerin doğrusal bir kombinasyonu olarak ifade edilmesi prensibine dayanmakta ve bu ilişkiyi optimize etmek için en küçük kareler yöntemini kullanmaktadır. Yöntem, sadece ilişkilerin varlığını ortaya koymakla kalmaz, aynı zamanda bu ilişkilerin büyüklüğünü ve yönünü de belirleyerek değişkenlerin önem derecesini analiz etmeye olanak tanımaktadır. Çok değişkenli doğrusal regresyon, veri analizinde güçlü bir temel sağlayarak; bağımsız değişkenlerin bağımlı değişken

üzerindeki katkılarını nicel olarak değerlendirmek için sıklıkla kullanılan bir yöntemdir (Rath & Tripathy, 2020).

Denklem (22), bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki doğrusal ilişkiyi modellemek için kullanılan temel regresyon denklemini göstermektedir. Regresyon katsayıları (β) bağımsız değişkenlerin bağımlı değişken üzerindeki etkisinin büyüklüğünü ve yönünü belirlemektedir. Denklemin amacı, hata terimini (ε) en aza indirerek bağımlı değişkeni en iyi şekilde tahmin eden bir model oluşturmaktır. Çok değişkenli doğrusal regresyon, özellikle birden fazla faktörün aynı anda analiz edilmesi gerektiği durumlar için güçlü bir analitik araç sunmaktadır.

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_k x_k + \varepsilon \quad (22)$$

Burada y , bağımlı değişkeni temsil eder ve modelin tahmin etmeye çalıştığı sonuç değişkenidir. Sabit terim olan β_0 , bağımsız değişkenlerin etkisi olmaksızın y üzerindeki temel değeri ifade etmektedir. Bağımsız değişkenlerin katsayıları olan $\beta_1, \beta_2, \dots, \beta_k$ her bir bağımsız değişkenin ($x_1, x_2, \dots, x_k$) bağımlı değişken üzerindeki etkisinin büyüklüğünü ve yönünü tanımlamaktadır. Bu katsayılar, bağımsız değişkenler ile y arasındaki doğrusal ilişkinin gücünü belirlemektedir. Ayrıca, ε hata terimi olarak adlandırılmakta ve modelin açıklayamadığı veya rastgele etkilerden kaynaklanan sapmaları içermektedir. Bu modelin amacı, hata terimini en aza indirerek bağımlı değişkeni bağımsız değişkenler yardımıyla en doğru şekilde tahmin etmektir.

2.4. VERİ TOPLAMA SÜRECİ

Türkiye'nin tarım sektörü, ekonomik kalkınma ve kırsal sürdürülebilirlik açısından stratejik bir öneme sahiptir. Bu bağlamda, tarım kredilerinin tahmini için kullanılacak değişkenler, sektörel dinamiklerin çok boyutlu bir analizini mümkün kılmaktadır. Tarım arazisi oranı ve sulanan tarım arazisi, tarımsal üretim kapasitesinin fiziksel altyapısını ve kaynak verimliliğini yansıtırken; tarım, ormancılık ve balıkçılığın GSYİH'ye katkısı ve tarımsal ham madde ihracatı, sektörün makroekonomik performansını ve dış ticaretteki önemini vurgulamaktadır. Kentsel nüfus artışı ve kentsel nüfus oranı gibi demografik göstergeler, kırsal nüfus azalması ve mekanizasyon ihtiyacının kredi taleplerine olan etkilerini anlamaya olanak tanımaktadır. Tarımda istihdam oranı, sektördeki iş gücü dinamiklerini ve üretim süreçlerindeki değişimi açıklarken; bitkisel ve gıda üretim endeksleri ile gübre tüketimi, üretim düzeyinin sürekliliği ve girdilere olan bağımlılıkla ilgili önemli ipuçları sunmaktadır. Son olarak, yıllık tatlı su çekimi, doğal kaynak yönetiminin tarımsal faaliyetlere etkisini ve bu çerçevede ortaya çıkan finansman ihtiyaçlarını ele almaktadır. Bu değişkenlerin kapsamlı analizi, tarım kredilerinin tahminine yönelik ekonomik modellerin daha etkin ve isabetli bir şekilde

tasarlanmasını sağlayarak politika yapıcılar ve finansal kuruluşlar için kritik bir yol haritası oluşturacaktır.

Bu çalışma, Türkiye'nin tarım sektörüne yönelik kredi taleplerinin tahmini amacıyla, 2000-2022 dönemini kapsayan geniş bir veri setine dayanmaktadır. Çalışmada kullanılan 11 değişken, sektörel dinamikleri ve ekonomik etkileşimleri çok boyutlu bir perspektifte ele almaktadır. Tarım arazisi oranı ve sulanan tarım arazisi gibi göstergeler, tarımsal üretim kapasitesinin fiziksel altyapısını ve kaynak kullanım etkinliğini yansıtırken; tarım, ormancılık ve balıkçılığın GSYİH'ye katkısı ve tarımsal ham madde ihracatı, tarım sektörünün makroekonomik performansını ve dış ticaretteki stratejik önemini ortaya koymaktadır. Kentsel nüfus artışı ve kentsel nüfus oranı gibi demografik göstergeler, kırsal-şehir dinamiklerinin sektörel iş gücü ve mekanizasyon üzerindeki etkilerini analiz etme imkânı sunmaktadır. Tarımda istihdam oranı, tarımsal iş gücü değişimlerini ve üretim süreçlerini anlamak için kritik bir ölçüt olarak ele alınırken; bitkisel üretim endeksi, gıda üretim endeksi ve gübre tüketimi, tarımsal üretim düzeyinin sürdürülebilirliğine dair önemli göstergelerdir. Son olarak, yıllık tatlı su çekimi, doğal kaynakların kullanımına ilişkin sektörel bağımlılık düzeyini ve bu bağlamda finansal gereksinimleri yansıtmaktadır. Farklı güvenilir kaynaklardan derlenen bu değişkenler, tarım sektöründeki yapısal değişimlerin ve kredi taleplerinin belirleyicilerinin kapsamlı bir şekilde analiz edilmesine olanak tanımaktadır. Bu veri seti, tarım kredilerinin tahminine yönelik ileri düzey modelleme çalışmaları için sağlam bir temel sunmaktadır. Değişkenlere ait bilgiler, birimler, kısaltmalar ve veri kaynakları Tablo 3'te verilmiştir. Bu tablo, her bir değişkenin tanımını, ölçüm birimini, kullanılan kısaltmaları ve verilerin temin edildiği kaynakları içermektedir.

Tablo 3: Değişkenler, Birimleri ve Kaynakları (2000-2022)


Değişken	Kısaltma	Veri Kaynağı
Tarım arazisi (% arazi alanı)	TA	WoldBank
Tarım, ormancılık ve balıkçılık, katma değer (% GSYİH)	KD	WoldBank
Kentsel nüfus artışı (yıllık %)	KNA	WoldBank
Tarımda istihdam (% toplam istihdam)	Tİ	WoldBank
Sulanan tarım arazisi (% toplam tarım arazisi)	STA	WoldBank
Tarımsal ham madde ihracatı (% toplam mal ihracatı)	THMİ	WoldBank
Bitkisel üretim endeksi (2014-2016 = 100)	BÜE	WoldBank
Gıda üretim endeksi (2014-2016 = 100)	GÜE	WoldBank
Gübre tüketimi (% gübre üretimi)	GT	WoldBank
Yıllık tatlı su çekimi, tarım (% toplam tatlı su çekimi)	TSC	WoldBank

Kentsel nüfus (% toplam nüfus)	KNA	WoldBank
Tarım Kredisi	TK	(FaoStat)

2.5. DEĞİŞKENLERİN TREND ANALİZİ

2.5.1. Tarım Arazisi (% Arazi Alanı)

Tarım arazisinin toplam alanındaki oranı, tarım sektörünün büyüklüğünü ve tarımsal üretimin potansiyelini belirlemektedir. Tarım arazisi oranı ne kadar yüksekse, tarım üretiminin artırılması için gereken yatırımlar da o kadar büyük olmaktadır. Ekilen tarım arazisi miktarı arttıkça tarım kredilerine olan ihtiyaçlarda paralel olarak artacağı öngörülmektedir. Tarım kredileri, bu arazilerin daha verimli hale getirilmesi için gerekli olan ekipman, sulama sistemleri, toprak işleme ve modern tarım tekniklerinin uygulanmasında kritik rol oynamaktadır. Ayrıca, sınırlı tarım arazisi bulunan yerlerde, mevcut arazilerin en verimli şekilde kullanılması için finansal kaynak sağlanması gerekmektedir. Sınırlı tarım arazilerinde istenilen üretim miktarı kısıtlı kaldığı durumlarda finansal kaynaklara olan ihtiyaç daha da çok artacaktır. Şekil 7’de Türkiye için 2000-2022 yılları arasında tarım arazisi kullanımının yıllık değişimi verilmiştir.




Şekil 7: Türkiye'deki Tarım Arazisi Kullanımının Yıllık Değişimi (% Arazi Alanı)

Şekil 7’de, Tarım Arazisi (% Arazi Alanı) değişkeninin 2000-2022 yılları arasındaki trendi incelenmiştir. Veriler, tarımsal üretim kapasitesinin fiziksel altyapısını ve arazi kullanımında meydana gelen değişimleri yansıtmaktadır. Grafik incelendiğinde, tarım arazisi oranında genel olarak istikrarlı bir seyir gözlenmektedir; ancak bazı yıllarda sınırlı

dalgalanmalar dikkat çekmektedir. Bu durum, tarım arazisi kullanımının büyük ölçüde sabit kaldığını ancak dönemsel olarak arazi kaybı veya kazanımının gerçekleşmiş olabileceğini göstermektedir. Dalgalanmalar, iklim koşullarındaki değişimler, arazi kullanım politikalarındaki dönüşümler veya kentsel yayılma gibi faktörlerle ilişkilendirilebilir. Grafikteki istikrar, Türkiye'nin tarım sektörü için temel fiziksel altyapının korunduğunu ve tarım arazisi miktarının üretim kapasitesini destekleyecek düzeyde sürdürüldüğünü işaret etmektedir. Ancak, ilerleyen yıllarda tarımsal sürdürülebilirlik açısından, bu arazilerin etkin bir şekilde korunması ve değerlendirilmesi büyük önem taşımaktadır. Daha detaylı analizler, tarım arazisi kullanımının neden olduğu değişimlerin sosyo-ekonomik etkilerini ve kredi taleplerine olan yansımalarını ortaya koyabilir.

2.5.2. Tarım, Ormancılık ve Balıkçılık, Katma Değer (% GSYİH)

Tarım sektörünün, gayri safi yurtiçi hasılaya (GSYİH) katkısı, bir ülkenin ekonomisindeki tarımın rolünü göstermektedir. Katma değer oranının düşük olduğu yerlerde, sektörü modernize etmek, verimliliği artırmak ve daha yüksek katma değerli ürünler elde etmek için tarım kredilerine ihtiyaç duyulmaktadır. Bu krediler, çiftçilerin daha verimli üretim süreçlerine, yeni teknolojilere ve işleme tesislerine yatırım yapmalarını sağlarken, sektörde daha yüksek gelir elde edilmesine olanak tanımaktadır. Yüksek katma değerli tarımsal ürünler hem iç pazarda hem de dış pazarda daha rekabetçi olmayı katkıda bulunacaktır. Tarımsal üretimde katma değer artması üreticinin daha yüksek gelir elde sağlayarak finansal açıdan daha yüksek hacimli iş potansiyeli ortaya çıkaracaktır. Bu potansiyel, tarımsal kredilere olan talebi artıracak ve GSYİH içindeki tarımın yüzdelik etkisi pozitif yönde etki sağlayacaktır.




Şekil 8: Türkiye'de Tarım, Ormancılık ve Balıkçılığın GSYİH'ye Katkısı (2000-2022)

Şekil 8’de, Türkiye’de Tarım, Ormancılık ve Balıkçılık Katma Değerinin (% GSYİH) 2000-2022 yılları arasındaki değişimini göstermektedir. Veriler, bu sektörlerin Gayri Safi Yurtiçi Hasıla (GSYİH) içindeki yüzdesel katkısında genel bir azalma eğilimini ortaya koymaktadır. Ekonomideki yapısal dönüşümler ve sanayi ile hizmet sektörlerinin büyümesi, tarım sektörünün payının azalmasında etkili olmaktadır. Bununla birlikte, grafik üzerinde dikkat çeken dönemsel artışlar, tarım politikalarındaki iyileştirmeler, olağanüstü iklim koşullarına bağlı üretim artışları veya kriz dönemlerinde uygulanan destek mekanizmalarıyla ilişkilendirilebilir.

Bu azalan trend, tarım sektörünün finansal sürdürülebilirlik ve rekabet gücü açısından zorluklarla karşı karşıya olduğunu göstermektedir. Özellikle tarım kredilerine olan talebin, sektördeki bu gerilemeye rağmen artış gösterebileceği düşünülebilir. Çünkü azalan katkı, daha fazla yatırım ve modernizasyon ihtiyacını da beraberinde getirebilir. Ayrıca, ormancılık ve balıkçılık gibi alt sektörlerin tarımın toplam performansı üzerindeki etkilerinin ayrı ayrı incelenmesi, bu katkının daha detaylı bir şekilde anlaşılmasını sağlayabilmektedir. Bu bağlamda, sektörün ekonomik büyüme içerisindeki rolünü artırmak için daha güçlü teşvik politikalarının ve finansman desteğinin hayata geçirilmesi önerilebilir. Tarım sektörünün GSYİH içindeki payını analiz etmek, kredi politikalarının şekillendirilmesinde ve sektörel kalkınma stratejilerinin belirlenmesinde kritik bir öneme sahiptir.

2.5.3. Kentsel Nüfus Artışı (Yıllık %)

Kentsel nüfus artışı, kırsal alanlardan şehirlere göçü artırırken, şehirlerdeki gıda talebinin de artmasına neden olmaktadır. Bu, tarım sektöründe üretimin artırılması gerekliliğini doğurmaktadır. Tarım kredileri, kırsal alanlardaki üretimin artırılmasına yönelik yatırımlar için önemli bir kaynaktır. Bu kredilerle çiftçiler, verimli tarım teknikleri, sulama sistemleri ve yüksek kaliteli gıda üretimine yönelik teknolojilere yatırım yapabileceklerdir. Artan kentsel nüfus, tarıma dayalı üretim süreçlerini daha verimli hale getirecek projelerin finansmanını zorunlu kılmaktadır. Her geçen gün kırsal nüfusta yaşanan azalma daha yüksek ve kaliteli tarımsal üretim miktarını artırma zorunluluğunu ortaya koymaktadır. Kırsal nüfusa sağlanan tarımsal kredi miktarları kentsel nüfusun artmasıyla ortaya çıkan tüketim talebine yetişmek için artırılmalıdır.



Şekil 9: Kentsel Nüfus (% Toplam Nüfus) Trend Grafiği (2000-2022)


Şekil 9’da, Türkiye’de yıllık kentsel nüfus artış oranının 2000-2022 yılları arasında zamanla bir düşüş eğilimi gösterdiğini ortaya koymaktadır. Kentsel nüfus artış hızındaki bu azalma, kentleşme sürecinin zamanla daha olgun bir aşamaya geçiş yaptığını ve kırsaldan kente göç oranlarının yavaşladığını işaret etmektedir. Bu eğilim, kırsal bölgelerde kalan nüfusun azaldığını ve kentsel alanların doyumluk seviyesine yaklaştığını gösterebilir. Ayrıca, doğum oranlarındaki genel düşüş ve kentsel alanlardaki nüfus artış hızının doğal sınırlara yaklaşması da bu trendi etkileyen faktörler arasında yer alabilir.

Bu eğilimin tarım sektörüne etkisi ise iş gücü kaynaklarının azalarak mekanizasyona ve modern tarım yöntemlerine olan ihtiyacı artırması şeklinde görülebilecektir. Kentsel nüfus artış oranının düşmesi, kırsal bölgelerde daha fazla altyapı yatırımı ve tarımsal üretimin artırılmasına yönelik destek mekanizmalarını da gündeme getirebilmektedir. Tarım kredilerine olan etkisi açısından, kırsal nüfustan kaynaklanan kredi taleplerinde düşüş veya modernizasyon projeleri için artış gözlemlenebilecektir.

2.5.4. Tarımda İstihdam (% Toplam İstihdam)

Tarımda istihdam oranı, tarım sektörünün bir ülkenin iş gücü üzerindeki etkisini göstermektedir. Tarımda yüksek istihdam oranlarını yakalamak için tarımsal faaliyetlerin sürdürülebilirliğini ve kırsal kalkınmayı artırmaktan geçtiği söylenebilecektir. Tarım kredileri, iş gücünü daha verimli kullanmak için gerekli olan yatırımları finanse etmektedir. Örneğin, tarımsal üretimi artıracak teknolojilere (makineler, gübreleme sistemleri, sulama sistemleri) yönelik yapılan harcamalar, iş gücü verimliliğini artırmaya yardımcı olmaktadır. Bu krediler, kırsal alanda yeni iş alanları yaratılmasına ve sektördeki istihdamın artmasına destek olacaktır.

Tarımda istihdamın artmasıyla birlikte finans kaynağına olan talep artacak ve bu talep tarım kredileri miktarlarında artışa sebep olacaktır.



Şekil 10: Tarımda İstihdam (%Toplam İstihdam) Trend Grafiği (2000-2022)

Şekil 10'da, Tarımda İstihdamın (% Toplam İstihdam) 2000-2022 yılları arasındaki değişimini ortaya koymakta ve tarım sektöründeki istihdam oranında belirgin bir düşüş trendini gözler önüne sermektedir. Bu eğilim, Türkiye ekonomisinde yaşanan yapısal dönüşüm ve şehirleşme sürecinin doğrudan bir sonucudur. Sanayi ve hizmet sektörlerinin büyümesi, kırsal alanlardaki iş gücünün azalmasına yol açarken; modern tarım teknolojilerinin ve mekanizasyonun yaygınlaşması, tarımsal üretimde daha az iş gücüne ihtiyaç duyulmasını beraberinde getirmiştir.

Tarım sektöründeki bu dönüşüm, tarım kredileri üzerindeki etkilerini farklı boyutlarda göstermektedir. Azalan iş gücü, mekanizasyon ve modernizasyon yatırımlarına olan ihtiyacı artırarak bu alanlarda kredi taleplerini yükseltebilecektir. Ayrıca, kırsal bölgelerdeki küçük çiftliklerin finansal sürdürülebilirliğini sağlamak amacıyla daha fazla destek ve kredi talebi ortaya çıkabilecektir. Verimlilik artırıcı girdi ihtiyaçları, özellikle gübre, sulama ve tohum finansmanı için kredi gereksinimlerini tetikleyebilmektedir.

Sonuç olarak, tarımda istihdamın azalması, sektörde önemli yapısal değişikliklere işaret etmektedir. Bu durum, tarım sektörünün sürdürülebilirliği ve kırsal kalkınmanın desteklenmesi için politika yapıcıların hedef odaklı kredi stratejileri geliştirmesini gerektirmektedir. İstihdamdaki bu düşüşün etkilerinin kapsamlı bir şekilde analiz edilmesi, tarım kredilerinin gelecekteki yönelimlerini anlamak ve sektörel kalkınmayı desteklemek açısından kritik bir öneme sahiptir.

2.5.5. Sulanan Tarım Arazisi (% Toplam Tarım Arazisi)

Sulama, verimli tarım üretiminin temel unsurlarından biridir. Sulama altyapısının iyileştirilmesi, ürün verimliliğini artırır ve tarımda su kullanımını optimize etmeyi sağlamaktadır. Sulama sistemlerine yatırım, çiftçilerin verimli ve sürdürülebilir üretim yapabilmesi için oldukça önem arz etmektedir. Tarım kredileri, sulama sistemlerinin kurulumuna, modern sulama teknolojilerine ve su verimliliği artırıcı projelere olanak tanımaktadır. Sulanan tarım arazilerindeki artış kredi miktarına olan talebi artırmaktadır. Sulanan tarım arazisi arttıkça yatırım ve giderlerde oluşan maliyet ve ihtiyaçtan dolayı tarım kredilerine olan talebi artırmaktadır. Bu da tarımsal kredi miktarının artmasına yol açmaktadır.




Şekil 11: Sulanan Tarım Arazisi (% Toplam Tarım Arazisi) Trend Grafiği (2000-2022)

Şekil 11’de, Türkiye’de sulanan tarım arazisinin toplam tarım arazisine oranının 2000-2022 yılları arasındaki değişimini göstermektedir. Veriler incelendiğinde, sulanan tarım arazisi oranında genel olarak sınırlı bir artış eğilimi olduğu gözlemlenmektedir. Bu durum, sulama altyapısına yapılan yatırımların ve tarımsal üretimde modernizasyonun kademeli olarak ilerlediğine işaret etmektedir. Ancak, bu artışın düşük seviyelerde kalması, sulama sistemlerinin genişletilmesinde karşılaşılan ekonomik, teknik ve çevresel zorluklara işaret edebilecektir. Özellikle su kaynaklarının sınırlı olduğu bölgelerde sulama altyapısı projelerinin uygulanabilirliği, bu eğilimin sınırlı olmasının başlıca nedenlerinden biridir. Türkiye’nin tarımsal üretiminde sulama sistemlerinin genişletilmesi, su kaynaklarının verimli bir şekilde kullanılmasıyla doğrudan ilişkili olduğu düşünülmektedir. Sulama imkanlarının artırılması, tarımsal üretim verimliliğini artırarak toplam üretim düzeylerini olumlu etkileyebilmektedir. Ancak, su kaynaklarının sürdürülebilirliği de bu süreçte kritik bir öneme sahiptir. Özellikle

iklim değışiklięi bağlamında artan kuraklık riski, mevcut sulama altyapısının modernizasyonunun yanı sıra su tasarruflu yöntemlerin uygulanmasını gerektirmektedir.

2.5.6. Tarımsal Ham Madde İhracatı (% Toplam Mal İhracatı)

Tarımsal ürünlerin ihracatı, bir ülkenin ekonomik büyümesine katkı sağlamakta ve döviz kazancını artırmaktadır. Tarım kredileri, ihracat potansiyelini artıran projelere finansman sağlamaktadır. Tarımda daha verimli üretim, işleme kapasitesinin artırılması, ürün kalitesinin yükseltilmesi ve pazarlama faaliyetleri için tarım kredilerine ihtiyaç duyulmaktadır. Ayrıca, tarımsal ürünlerin uluslararası pazarda rekabet edebilmesi için yenilikçi üretim yöntemlerinin ve kalite standartlarının uygulanması gerekmektedir. Bu bağlamda, tarımsal ham madde ihracatının artması, tarım kredilerinin sektördeki büyüme üzerinde olumlu etkiler yaratmasını sağlamaktadır. Tarımsal hammadde ihracatındaki artışta yaşanan gelişmeler paralel olarak tarımsal kredi miktarını artırmaktadır.




Şekil 12: Tarımsal Ham Madde İhracatı (%) Trend Grafięi (2000-2022)

Şekil 12’de, Türkiye’de tarımsal ham madde ihracatının toplam mal ihracatı içindeki oranının 2000-2022 yılları arasındaki değışimi gösterilmektedir. Veriler incelendiğinde, tarımsal ham madde ihracatında özellikle 2000’li yılların başından itibaren belirgin bir düşüş trendi olduęu görülmektedir. 2000 yılında %1,1 seviyelerinde olan bu oran, 2005 yılına kadar keskin bir şekilde azalarak yaklaşık %0,4 seviyesine gerilemiştir. Bu eğilim, tarımsal ürünlerin dış ticaretteki göreceli öneminin azaldığını ve Türkiye’nin ihracat yapısında tarım dışı ürünlerin ağırlık kazandığını göstermektedir. 2005-2010 yılları arasında ise oran düşük seviyelerde stabil kalmış, 2010 yılı itibarıyla geçici bir artış eğilimi gözlemlenmiştir. Bu dönemsel artış, tarımsal ürünlere yönelik talebin artışı ya da tarım politikalarındaki teşviklerle ilişkilendirilebilmektedir.

Ancak bu artış kısa vadeli olmuş ve oran tekrar düşüş trendine geçmiştir. 2020 sonrası ise dikkat çekici bir artış eğilimi gözlemlenmiştir. Bu artış, pandemi sonrası tarım ürünlerine olan talebin artması, küresel ticaret dinamiklerindeki değişimler veya tarım sektörüne yönelik destek politikalarının etkisiyle açıklanabilmektedir.

2.5.7. Bitkisel Üretim Endeksi (2014-2016 = 100)

Bitkisel üretim endeksi, tarımsal üretim miktarını gösteren bir göstergedir ve sektördeki üretim artışını izlemeye yardımcı olmaktadır. Endeksin artması, tarımda verimliliğin arttığını gösterir ve bu artışı sürdürürebilmek için yatırımların artması gerekmektedir. Tarım kredileri, çiftçilerin daha verimli üretim tekniklerine ve modern teknolojilere yatırım yapmalarını sağlamaktadır. Bitkisel üretim arttıkça, çiftçiler daha fazla ürün yetiştirir ve dolayısıyla tarım kredilerinin önemi de artmaktadır. Bu krediler, üretim artışını desteklemek için gereken kaynakları sağlamaktadır.




Şekil 13: Bitkisel Üretim Endeksi (2014-2016=100) Trend Grafiği (2000-2022)

Şekil 13'te, Türkiye'deki bitkisel üretim endeksinin 2000-2022 yılları arasındaki değişimi gösterilmektedir. Endeks, tarımsal üretimin düzeyini 2014-2016 yılları arasındaki referans döneme göre değerlendirmektedir. Veriler incelendiğinde, bitkisel üretimde genel olarak düzenli bir artış trendi olduğu görülmektedir. 2000 yılında 80 seviyelerinde başlayan endeks, 2022 yılına kadar sürekli artarak 120 seviyesinin üzerine çıkmıştır. Bu artış trendi, tarımsal üretimdeki iyileştirmeler, modern tarım yöntemlerinin yaygınlaşması ve üretimde verimliliği artırmaya yönelik politikaların etkili bir şekilde uygulanmasıyla açıklanabilmektedir. Özellikle, sulama altyapısının kademeli olarak iyileştirilmesi ve tarımsal

mekanizasyonun artması, bitkisel üretimdeki bu olumlu eğilime katkıda bulunmaktadır. Ancak, 2009 ve 2015 yıllarında görülen geçici düşüşler, kuraklık, doğal afetler veya tarımsal girdilere erişimde yaşanan sorunlar gibi çevresel ve ekonomik faktörlerden kaynaklanmaktadır

2.5.8. Gıda Üretim Endeksi (2014-2016 = 100)

Gıda üretim endeksi, gıda üretiminin yeterliliğini ve sürdürülebilirliğini göstermektedir. Gıda üretiminin artırılması, tarım kredilerinin desteği ile mümkündür. Çiftçiler, bu kredilerle gıda üretiminde kullanılan altyapıyı iyileştirebilir, verimli tarım tekniklerini benimseyebilir ve üretim kapasitesini artırabilmektedir. Bu krediler, gıda güvenliğini sağlamak ve tarımsal üretimi sürekli kılmak için gerekli olan finansal kaynakları sağlamaktadır. Gıda üretiminin artması tarım kredilerine olan talebi etkilemektedir.



Şekil 14: Gıda Üretim Endeksi (2014-2016=100) Trend Grafiği (2000-2022)


Şekil 14’te, Türkiye’deki gıda üretim endeksinin 2000-2022 yılları arasındaki değişimi gösterilmektedir ve gıda üretiminin 2014-2016 referans dönemine göre nasıl bir gelişim gösterdiği açıklanmaktadır. Veriler incelendiğinde, endeksin 2000 yılında yaklaşık 70 seviyelerinde başladığı ve 2022 yılına kadar düzenli bir artış göstererek 130 seviyesini aştığı görülmektedir. Bu durum, Türkiye’nin gıda üretim kapasitesini artırmada istikrarlı bir ilerleme kaydettiğini ve gıda güvenliği açısından olumlu bir tablo sergilediğini göstermektedir. Endekste gözlemlenen bu artış, modern tarım yöntemlerinin benimsenmesi, sulama altyapısındaki iyileştirmeler ve tarımsal verimliliği artırmaya yönelik politikaların etkili bir şekilde uygulanmasıyla ilişkilendirilmektedir. Bununla birlikte, bazı yıllarda endeksin sabit kaldığı veya hafif düşüşler yaşadığı görülmektedir. Bu durgunluk dönemleri, iklim koşulları, tarımsal girdilere erişimde yaşanan zorluklar veya doğal afetler gibi çevresel ve ekonomik faktörlerle

açıklanabilmektedir. Özellikle, pandemi sonrası dönemde gözlemlenen hızlı artış, artan gıda talebi ve tarım sektörüne yönelik destek politikalarının etkisini yansıtmaktadır. Bu eğilimler, gıda üretim kapasitesinin artırılması konusunda atılan adımların başarılı olduğunu göstermektedir.

Türkiye'nin gıda üretim kapasitesindeki bu artışın sürdürülebilir şekilde devam edebilmesi için sulama altyapısının modernizasyonu, iklim değişikliğine uyumlu tarım yöntemlerinin yaygınlaştırılması ve çiftçilerin desteklenmesi için tarım kredilerinin etkin bir şekilde kullanılması gerekmektedir. Ayrıca, tarımsal üretimde çevresel sürdürülebilirliği sağlamak ve üretim dalgalanmalarını önlemek amacıyla daha kapsamlı politikalar geliştirilmelidir. Bu grafik, Türkiye'nin gıda üretim kapasitesindeki büyümeyi yansıtırken, bu büyümenin sürdürülebilir şekilde devam edebilmesi için yapılması gerekenleri de vurgulamaktadır.

2.5.9. Gübre Tüketimi (% Gübre Üretimi)

Gübre, tarımda verimliliği artıran önemli bir etkidir. Gübre tüketimi, üretimin kalitesini ve miktarını doğrudan etki etmektedir. Tarım kredileri, çiftçilerin gübre temini ve gübreleme teknolojilerine yatırım yapmalarını kolaylaştırmaktadır. Gübre kullanımının artırılması, toprak verimliliğini artırarak daha fazla ürün elde edilmesini sağlamaktadır. Bu krediler, gübre kullanımını optimize etmek için finansal destek sunar ve çevre dostu gübreleme yöntemlerini teşvik edebilmektedir. Gübreleme miktarının artması tarımda maliyetlerin artmasına ve tarım kredilerine olan ihtiyacı artırmasına neden olmaktadır. Buda finansal kuruluşların sağladığı tarımsal kredi miktarını artırmaktadır.




Şekil 15: Gübre Tüketimi (% Gübre Üretimi) Trend Grafiği (2000-2022)

Şekil 15’te, Türkiye’deki Gübre Tüketimi (% Gübre Üretimi) değişkeninin 2000-2022 yılları arasındaki trendi gösterilmektedir. Veriler, gübre tüketiminin başlangıçta üretimin oldukça üzerinde olduğunu ve zamanla bu oranın ciddi bir şekilde azaldığını ortaya koymaktadır. 2000 yılında %260 seviyesinde başlayan gübre tüketimi, 2022 yılına kadar düzenli bir düşüş sergileyerek %100 seviyesinin altına inmiştir. Bu, Türkiye’nin gübre üretiminde önemli bir artış yaşadığını ve dışa bağımlılığın azaldığını, ancak gübre tüketiminin üretim artışına kıyasla daha sınırlı bir düzeyde kaldığını göstermektedir. Grafikteki dalgalanmalar, gübre kullanımındaki dönemsel değişimleri işaret etmektedir. Özellikle 2010 ve 2015 yılları arasında gübre tüketim oranında görülen artışlar, tarımsal üretimde verimliliği artırmaya yönelik gübre kullanımının yoğunlaştığı dönemlere işaret etmektedir. Bununla birlikte, 2020 sonrası dönemde gübre tüketimindeki hızlı düşüş, ekonomik zorluklar, gübre fiyatlarındaki artış veya girdi maliyetlerinin çiftçiler üzerindeki baskısı ile açıklanabilmektedir. Bu durum, gübreye erişimin sınırlanması veya daha verimli gübre kullanım tekniklerinin benimsenmesiyle de ilişkilendirilir.

2.5.10. Yıllık Tatlı Su Çekimi, Tarım (% Toplam Tatlı Su Çekimi)

Tarım sektörü, tatlı su kaynaklarını yoğun şekilde kullanmaktadır. Tarım kredileri, suyun verimli kullanılması için gerekli olan altyapı yatırımlarını finanse etmeyi sağlamaktadır. Modern sulama sistemleri, su tasarrufu sağlayan yöntemler ve suyun etkin yönetimi gibi projeler, tarımda su kullanımını artırmaktadır. Bu krediler, su kaynaklarının korunmasını sağlarken, tarım sektöründeki sürdürülebilirliğini de artırmaktadır. Ayrıca, suyun verimli kullanımı, üretimin artırılmasını sağlayarak, çiftçilerin daha verimli üretim yapmalarına olanak tanımaktadır. Tatlı suya olan talep arttıkça suyun araziye ulaşmasında kullanılan sistemler ve harcanan enerji tüketimi gibi birçok girdi maliyeti tarımsal krediye olan talebi artırmaya neden olmaktadır.




Şekil 16: Tatlı Su Çekimi (% Tarım) Trend Grafiği (2000-2022)

Şekil 16’da, Türkiye’deki Tatlı Su Çekimi (% Tarım) değişkeninin 2000-2022 yılları arasındaki trendi gösterilmektedir. Veriler, toplam tatlı su çekiminde tarım sektörünün payının oldukça yüksek olduğunu ve dönem boyunca genel olarak %80 ile %88 arasında değiştiğini ortaya koymaktadır. 2000’li yılların başında %80 civarında olan oran, dönem boyunca hafif bir artış göstermiş ve 2010’lu yıllarda %86-88 seviyelerine ulaşmıştır. Ancak 2020 sonrası dönemde oran, hafif bir azalma eğilimi göstererek %86 seviyelerine gerilemiştir. Bu eğilim, tarım sektörünün su kaynaklarına olan yoğun bağımlılığını açıkça göstermektedir. Sulama, tarımsal üretimin en kritik girdilerinden biri olup, bu yüksek oranlar, tarım sektöründe su yönetimi politikalarının önemini vurgulamaktadır. Orandaki dönemsel dalgalanmalar, iklim koşulları, sulama altyapısındaki değişiklikler ve su kullanım verimliliğine yönelik yapılan yatırımlarla ilişkilendirilmektedir. Özellikle, kuraklık gibi doğal faktörler ile su kullanım teknolojilerindeki gelişmeler, bu dalgalanmaları etkileyen temel unsurlar arasında yer almaktadır.

2.5.11. Kentsel Nüfus (% Toplam Nüfus)

Kentsel nüfus oranı, tarım sektörünün şehirlerdeki gıda talebini karşılayacak şekilde büyümesini gerektirmektedir. Artan kentsel nüfus, daha fazla gıda üretimi yapılmasını zorunlu kılar ve bu da tarım kredilerine olan ihtiyacı artırmaya neden olmaktadır. Tarım kredileri, kırsal alanlarda üretim kapasitesini artıracak altyapı yatırımlarına, teknolojilere ve üretim süreçlerine yönlendirilmektedir. Kentsel nüfusun artışıyla birlikte, gıda güvenliği için daha fazla ve verimli tarımsal üretim yapılması gerekmektedir. Toplam nüfus içerisindeki kentsel nüfusun artması


tarımsal ürüne olan talebi artırması nedeniyle kırsal kesime sağlanan kredi miktarının artmasına neden olmaktadır.



Şekil 17: Kentsel Nüfus (%Toplam Nüfus) Trend Grafiği (2000-2022)

Şekil 17’de, Türkiye’deki Kentsel Nüfusun (% Toplam Nüfus) 2000-2022 yılları arasındaki trendi gösterilmektedir. Veriler, kentsel nüfusun toplam nüfus içerisindeki payının yıllar boyunca sürekli bir artış eğilimi sergilediğini ortaya koymaktadır. 2000 yılında %66 seviyesinde olan kentsel nüfus oranı, 2022 yılına kadar düzenli bir şekilde artarak %76 seviyesine ulaşmıştır. Bu eğilim, kırsaldan kente göçün devam ettiğini ve Türkiye’nin şehirleşme sürecindeki ilerlemesini göstermektedir. Bu sürekli artış, ekonomik ve sosyal değişimlerle ilişkilendirilmektedir. Özellikle sanayi ve hizmet sektörlerindeki büyüme, kırsal kesimden kentlere olan göçü teşvik etmektedir. Aynı zamanda, kentlerdeki eğitim, sağlık ve altyapı imkanlarının kırsal bölgelere kıyasla daha cazip olması da kentsel nüfusun artışını destekleyen faktörlerden biridir. Bununla birlikte, kırsal bölgelerde tarım sektöründeki istihdamın azalması ve mekanizasyonun yaygınlaşması, kırsal nüfusun şehirlerde iş aramaya yönelmesine neden olmuş olabilir.

2.5.12. Tarım Kredisi (Milyon USD)



Şekil 18: Tarım Kredisi (Milyon USD) Trend Grafiği (2000-2022)

Şekil 18’de, Türkiye’deki Tarım Kredisi (Milyon USD) tutarlarının 2000-2022 yılları arasındaki değişimi gösterilmektedir. Veriler incelendiğinde, tarım kredilerinde 2000 yılındaki yaklaşık 3500 milyon USD seviyesinden itibaren hızlı bir düşüş yaşandığı ve 2010 yılı sonrasında kredi kullanımının düşük seviyelerde seyrettiği görülmektedir. Özellikle 2000-2005 yılları arasında keskin bir azalma yaşanmış ve bu dönemi takip eden yıllarda tarım kredilerinde daha stabil ancak düşük bir seviyede devam eden bir trend ortaya çıkmıştır. Bu keskin düşüş, 2000’li yılların başında Türkiye ekonomisinde yaşanan kriz ve buna bağlı olarak tarım sektöründeki finansman olanaklarının azalmasıyla açıklanmaktadır. Ayrıca, tarımsal kredi politikalarında yapılan değişiklikler veya kredi faiz oranlarının artması, tarım sektörü için finansmana erişimi zorlaştırmıştır. 2010 yılı sonrasında ise tarım kredilerinde düşük bir istikrar gözlemlenmektedir. Bu durum, finansman araçlarının sınırlı kullanımını veya çiftçilerin krediye olan talebindeki azalmayı göstermektedir.

Gelişmekte olan ülkelerde tarım sektörü, ekonomik büyümenin ve kırsal kalkınmanın önemli bir bileşenidir. Ancak, Türkiye gibi gelişmekte olan ülkelerde tarım kredilerindeki azalma, sektördeki modernizasyon ve üretim kapasitesini artırma çabalarını olumsuz yönde etkilemektedir. Tarım kredileri, çiftçilerin üretim girdilerine (tohum, gübre, sulama ekipmanları gibi) erişimini sağlamak, teknolojik yatırımları teşvik etmek ve iklim değişikliği gibi çevresel zorluklara karşı dayanıklılığı artırmak için kritik bir finansman kaynağıdır. Kredilerdeki düşüş, özellikle küçük ve orta ölçekli çiftliklerin finansal sürdürülebilirliğini tehlikeye atmaktadır ve bu durum, kırsal alanlardaki yoksulluk ve işsizliğin artmasına neden olmaktadır (Binswanger

& Khandker, 1995). Tarım kredilerindeki azalma, çeşitli faktörlerle ilişkilendirilmektedir. Finansal kurumların yüksek risk algısı, kırsal alanlarda yeterli kredi altyapısının olmaması ve çiftçilerin kredilere erişim konusundaki yetersiz bilgi düzeyi, bu düşüşün temel nedenleri arasında yer almaktadır. Ayrıca, kredi faiz oranlarının yüksek olması ve geri ödeme süreçlerinin çiftçilerin gelir döngüsüyle uyumlu olmaması, çiftçilerin kredi talebini sınırlamaktadır. Gelişmekte olan ülkelerdeki bu durum, tarım sektörünün rekabet gücünü ve küresel pazarlardaki yerini zayıflatabilir (Meyer, 2013).

Özetle, gelişmekte olan ülkelerde tarım kredilerine erişimin artırılması, kırsal kalkınmayı desteklemek ve tarımsal üretimi artırmak için stratejik bir gerekliliktir. Bu bağlamda, Türkiye gibi ülkelerde uygun faiz oranlarına sahip kredilerin çiftçilere sunulması, tarımsal riskleri azaltacak sigorta mekanizmalarının geliştirilmesi ve finansal okuryazarlık düzeyinin artırılması gerekmektedir. Ayrıca, tarım kredilerinin kullanımında hedef odaklı politikalar geliştirilerek, sulama altyapısının modernizasyonu, iklim değişikliğine dayanıklı ürünlerin geliştirilmesi ve sürdürülebilir tarım uygulamalarının yaygınlaştırılması sağlanmalıdır.

2.6. EKSİK VERİ ANALİZİ VE TAMAMLAMA

Makine öğrenmesi modellerinde eksik veri tamamlama, modelin doğruluğunu ve genelleştirme kapasitesini artırmak için kritik bir adımdır. Eksik veriler, modelin bağımsız değişkenler ile hedef değişken arasındaki ilişkileri doğru bir şekilde öğrenmesini engelleyebilmekte ve tahminlerde yanlılık ile hatalara neden olabilmektedir (Little & Rubin, 2002). Veri yoğunluğu gerektiren makine öğrenmesi algoritmalarında eksik veri sorunları, modelin performansını düşürdüğü gibi öngörülerin güvenilirliğini de azaltabilmektedir (Schafer & Graham, 2002). Bu nedenle, eksik verilerin uygun yöntemlerle tamamlanması hem veri setinin bütünlüğünü sağlamak hem de öğrenme sürecini optimize etmek için hayati önem taşımaktadır. Eksik veri tamamlama, eksik değerlerin olduğu durumlarda bu boşlukları doldurarak veri setinin daha tutarlı bir şekilde kullanılmasını sağlamaktadır. Eksik verilerin doğrudan gözlemlerden çıkarılması, veri setinin küçülmesine ve modelin öğrenme kapasitesinin sınırlanmasına yol açabilmektedir (Acuna & Rodriguez, 2004).

Tamamlama yöntemleri, modelin her bir gözlemi değerlendirmesine olanak tanıyarak daha geniş bir veri kümesi üzerinden öğrenme gerçekleştirmesini mümkün hale getirmektedir. Bu durum hem modelin genelleştirme yeteneğini artırmakta hem de tahminlerin daha güvenilir olmasını sağlamaktadır. Eksik veri tamamlama stratejileri arasında ortalama ile doldurma, regresyon tabanlı tamamlama, KNN tabanlı tamamlama ve ileri düzey makine öğrenmesi yöntemleri yer almaktadır (Batista & Monard, 2003). Her yöntemin performansı, eksik verilerin

doğasına ve veri setinin yapısına bağlıdır. Örneğin, rastgele eksikliklerde ortalama ile doldurma etkili olabilirken, sistematik eksikliklerde daha karmaşık yöntemler tercih edilmelidir (Allison, 2001). Ayrıca, eksik veri tamamlama sırasında veri dağılımının ve yapısının bozulmamasına dikkat edilmelidir, çünkü yanlış bir tamamlama yöntemi model performansını olumsuz yönde etkileyebilecektir.

Sonuç olarak, eksik veri tamamlama, makine öğrenmesi modellerinin daha sağlam, doğru ve güvenilir sonuçlar üretmesi için temel bir süreçtir. Eksik verilerle çalışmanın karmaşıklıkları, uygun tamamlama stratejilerinin dikkatlice seçilmesini gerektirir. Literatürde de vurgulandığı üzere (Little & Rubin, 2002; Schafer & Graham, 2002) eksik veri tamamlama, başarılı bir model geliştirme sürecinin vazgeçilmez bir parçasıdır ve modelin tüm veri setini etkin bir şekilde değerlendirmesine olanak tanır. Sulanan tarım arazisi (% toplam tarım arazisi), gübre tüketimi (% gübre üretimi) ve yıllık tatlı su çekimi, tarım (% toplam tatlı su çekimi) değişkenlerine ait veri setinde eksik gözlemler tespit edilmiştir. Veri setindeki bu eksikliklerin giderilmesi amacıyla, eksik gözlemler için lineer interpolasyon yöntemi kullanılmıştır. Lineer interpolasyon, eksik verilerin, mevcut komşu veri noktaları arasındaki doğrusal ilişkiye dayalı olarak tahmin edilmesine olanak tanıyan etkili ve yaygın bir yöntemdir (Zhang, 2016). Bu yaklaşım, eksik veri tamamlama sürecinde veri setinin genel yapısını ve eğilimlerini koruyarak analizlerin tutarlılığını sağlamıştır. Böylece, eksik gözlemlerden kaynaklanabilecek yanlışlıklar ve modelleme sürecinde oluşabilecek potansiyel performans kayıpları en aza indirilmiştir.

2.7. İSTATİSTİKSEL ÖZET VE DEĞERLENDİRME

Tanımlayıcı istatistikler, regresyon problemlerinde veri setini anlamak ve modelin doğruluğunu artırmak için kritik bir rol oynamaktadır. Regresyon analizinde bağımsız ve bağımlı değişkenlerin dağılımını, ortalama, standart sapma, minimum ve maksimum gibi ölçütlerle incelemek, veri setinin temel özelliklerini anlamaya olanak tanımaktadır. Özellikle bağımsız değişkenlerin farklı ölçeklerde olması, regresyon katsayılarının yorumlanabilirliğini zorlaştırabilir ve bu durum, tanımlayıcı istatistikler aracılığıyla ölçekleme veya standartlaştırma gereksinimini belirlemeyi sağlamaktadır. Ayrıca, uç değerlerin ve aykırıların tespiti, regresyon modelinin tahminlerini ciddi şekilde etkileyebileceğinden, bu tür değerlerin tanımlayıcı istatistiklerle belirlenmesi ve uygun şekilde ele alınması modelin doğruluğunu artırmaktadır. Eksik verilerin fark edilmesi ve doldurulması, regresyon modelinin sağlıklı bir şekilde çalışması için önemlidir ve tanımlayıcı istatistikler bu eksiklikleri belirlemek için bir başlangıç noktası sunacaktır.

Bağımlı değişkenin normal dağılıma uygunluğu, regresyon modelleri için kritik bir varsayımdır; bu nedenle, tanımlayıcı istatistikler yardımıyla dağılımın değerlendirilmesi ve

gerektiğinde dönüşüm yöntemlerinin uygulanması gerekmektedir. Ayrıca, bağımsız değişkenlerin varyansları, hangi değişkenlerin modele anlamlı katkı sağlayabileceğini anlamak ve çoklu doğrusallık problemi gibi sorunları değerlendirmek açısından önemlidir. Tüm bu bilgiler, modelin tahmin doğruluğunu artırmak, daha genellenebilir sonuçlar elde etmek ve değişkenler arasında etkili bir ilişki kurmak için gerekli altyapıyı oluşturmaktadır. Sonuç olarak, tanımlayıcı istatistiklerin dikkatlice incelenmesi, regresyon problemlerinde başarılı bir modelleme süreci için vazgeçilmez bir adım olmaktadır.

2.7.1. Korelasyon Analizi: Tarımsal ve Ekonomik Faktörler

Makine öğrenmesi modelleri geliştirilirken korelasyon analizi, veri ön işleme aşamasında kritik bir adımdır ve modellerin doğruluğunu, genelleştirme kapasitesini ve güvenilirliğini doğrudan etkilemektedir. Korelasyon analizi, bir değişkenin diğeriyle nasıl bir doğrusal ilişki içinde olduğunu ölçerek, modelleme sürecinin temel taşlarını oluşturmaktadır.

Korelasyon analizi, öncelikle bağımlı (hedef) ve bağımsız (özellik) değişkenler arasındaki ilişkileri anlamak için kullanılmaktadır. Güçlü bir korelasyon, bir değişkenin diğerini tahmin etmede etkili olduğunu göstermekte ve bu da modelin öğrenme sürecini kolaylaştırmaktadır. Bunun yanı sıra, bağımsız değişkenler arasında yüksek derecede bir korelasyonun varlığı, modelin öğrenme kapasitesini ve performansını olumsuz yönde etkilemektedir. Bu tür durumlarda, gereksiz veya tekrarlayıcı (redundant) değişkenlerin modelden çıkarılması gerekmektedir. Böylelikle modelin sadece anlamlı özelliklere odaklanması sağlanmakta ve bu da hem hesaplama maliyetlerini düşürmekte hem de modelin genelleştirme yeteneğini artırmaktadır (Guyon & Elisseeff, 2003).

Ek olarak, korelasyon analizi, özellik mühendisliği aşamasında da rehberlik etmektedir. Örneğin, değişkenler arasında zayıf bir ilişki bulunuyorsa, bu durum yeni türev değişkenlerin oluşturulmasını veya mevcut değişkenlerin dönüşümden geçirilmesini gerektirebilmektedir. Bununla birlikte, korelasyon analizinin nedenselliği değil, sadece ilişkiyi ortaya koyduğunun unutulmaması gerekmektedir. Bu nedenle, korelasyon analizi sonucunda ortaya çıkan ilişkiler, teorik çerçeve ve alan bilgisiyle birlikte değerlendirilmelidir.

Son olarak, korelasyon analizi, veri setindeki olası hataları veya olağan dışı ilişkileri tespit etmek için de kullanılmaktadır. Bu, veri kalitesini artırarak modelleme sürecinin sağlam bir temele oturmasını sağlamaktadır. Tarım kredileri gibi ekonomik ve sosyal veriler üzerinde çalışırken, değişkenler arasındaki ilişkileri anlamadan bir model geliştirmek, elde edilen sonuçların güvenilirliğini ve açıklanabilirliğini olumsuz etkilemektedir. Bu bağlamda

korelasyon analizi, makine öğrenmesi projelerinin başlangıç aşamasında mutlaka uygulanması gereken bir adım olarak kabul edilmektedir.

Yapılan korelasyon analizi, tarım kredilerinin miktarı ile çeşitli sosyo-ekonomik ve tarımsal değişkenler arasındaki ilişkilerin anlaşılmasına katkı sağlamaktadır. Analiz sonuçları, pozitif ve negatif korelasyonlar çerçevesinde aşağıdaki gibi değerlendirilmiştir:

2.7.1.1. Pozitif korelasyon gösteren değişkenler

1. Tarım, ormancılık ve balıkçılık katma değeri (gsyh'ye oranı) ile tarım kredileri

Tarım sektörünün GSYH içindeki payının artması, tarım kredilerinin miktarının artmasıyla yüksek derecede pozitif bir ilişki göstermektedir ($r = 0.879$). Bu ilişki, tarım sektörünün ekonomiye katkısının arttığı dönemlerde, finansal destek ihtiyacının da arttığını göstermektedir. Bu bulgu, tarımsal büyümenin ekonomik kalkınmaya olan etkisini desteklemektedir.

2. Tarımda istihdam (toplam istihdama oranı) ile tarım kredileri

Tarım sektöründeki istihdam oranının artışı, tarım kredilerinin miktarı ile güçlü bir pozitif korelasyon sergilemektedir ($r = 0.871$). Bu durum, tarım sektöründe çalışan sayısının artışıyla birlikte tarımsal faaliyetlerin genişlediğini ve bu genişlemenin finansal destek ihtiyacını artırdığını göstermektedir.

3. Tarımsal arazi oranı ile tarım kredileri

Tarımsal arazinin toplam arazi içindeki oranı ile tarım kredileri arasında pozitif bir ilişki bulunmaktadır ($r = 0.791$). Tarımsal faaliyetlerin geniş alan gerektirdiği ve bu alanların finansman ihtiyacını artırdığı gözlemlenmektedir.

2.7.1.2. Negatif korelasyon gösteren değişkenler

1. Sulanan tarım alanlarının oranı ile tarım kredileri

Tarımsal sulanan arazinin toplam tarım alanlarına oranı arttıkça, tarım kredilerinin miktarı azalma eğilimi göstermektedir ($r = -0.839$). Bu ilişki, sulama altyapısının gelişmiş olduğu bölgelerde finansal desteğin daha az gereksinim duyulduğu veya bu ihtiyaçların farklı kaynaklardan karşılandığına işaret etmektedir.

2. Şehirleşme oranı ile tarım kredileri

Şehirleşme oranı ile tarım kredileri arasında güçlü bir negatif korelasyon bulunmaktadır ($r = -0.923$). Şehirleşmenin artması, tarımsal faaliyetlerin azalmasına ve buna bağlı olarak tarımsal finansman ihtiyacının düşmesine neden olmaktadır. Bu bulgu, tarım sektöründeki ekonomik aktivitenin şehirleşme ile ters orantılı olduğunu göstermektedir.

3. Tarımsal su kullanımının toplam su kullanımına oranı ile tarım kredileri

Tarımsal su kullanım oranı arttıkça, tarım kredileri miktarında azalma gözlemlenmiştir ($r = -0.761$). Bu ilişki, su kaynaklarına bağımlı tarım bölgelerinde farklı destek mekanizmalarının devrede olabileceğini düşündürmektedir.

Analiz sonuçları, tarım kredilerinin dağıtımında etkili olan sosyo-ekonomik ve çevresel faktörlerin anlaşılmasına ışık tutmaktadır. Pozitif korelasyon gösteren değişkenler, tarım kredilerinin tahmin edilmesinde önemli özellikler olarak değerlendirilebilirken, negatif korelasyon gösteren değişkenlerin de sektörel dinamiklere etkisi dikkatle incelenmelidir. Özellikle, şehirleşme oranı ve sulanan tarım alanları gibi değişkenler, tarımsal faaliyetlerin ve finansman ihtiyaçlarının dönüşümünü yansıtmaktadır. Model geliştirme sürecinde, bu değişkenler arasındaki güçlü korelasyonların (çoklu doğrusallık problemi) dikkate alınması ve gerekli durumlarda özellik seçiminde ya da dönüşümlerinde düzenlemeler yapılması önerilmektedir.

VIF (Variance Inflation Factor), regresyon modellerinde bağımsız değişkenler arasında çoklu doğrusallık problemi olup olmadığını belirlemek için kullanılan bir metriktir. Çoklu doğrusallık problemi, bağımsız değişkenlerin birbirleriyle yüksek derecede doğrusal ilişki içinde olması durumudur ve bu durum modelin güvenilirliğini olumsuz yönde etkileyebilecektir. Özellikle regresyon katsayılarının tahmin edilebilirliğini zayıflatmakta ve değişkenlerin modeldeki katkısının doğru bir şekilde değerlendirilmesini zorlaştırmaktadır (Kutner vd., 2005).

VIF, bir bağımsız değişkenin diğer bağımsız değişkenler tarafından ne kadar açıklanabildiğini gösterir. Bir değişkenin VIF değeri ne kadar yüksekse, diğer değişkenlerle olan doğrusal ilişkisinin o kadar güçlü olduğu görülmektedir. Tablo 4’de VIF sonuçları görülmektedir.

Tablo 4: Bağımsız Değişkenler İçin VIF Değerleri

Değişken	VIF
Tarım arazisi (% arazi alanı)	41,779
Tarım, ormancılık ve balıkçılık, katma değer (% GSYİH)	6,526419
Tarımda istihdam (% toplam istihdam)	9,917992
Sulanan tarım arazisi (% toplam tarım arazisi)	60,13526
Yıllık tatlı su çekimi, tarım (% toplam tatlı su çekimi)	4,693388
Kentsel nüfus (% toplam nüfus)	21,72478
Sabit Terim (Intercept)	175922,3

Tablo 4’e göre, yüksek VIF değerlerine sahip değişkenler arasındaki korelasyonlar dikkat çekmektedir. Tarım arazisi (% arazi alanı) ile Sulanan tarım arazisi (% toplam tarım

arazisi) arasında -0.985 korelasyon katsayısı ile çok güçlü negatif bir ilişki bulunmaktadır. Bu durum, tarım alanlarının toplam arazi içindeki oranı azaldıkça, sulanan tarım arazilerinin toplam tarım alanlarına oranının arttığını göstermektedir. Benzer şekilde, Tarım arazisi (% arazi alanı) ile Kentsel nüfus (% toplam nüfus) arasındaki korelasyon katsayısı -0.923 olarak tespit edilmiştir. Bu bulgu, tarım alanlarının oranı azaldıkça şehirleşme oranının arttığını ve şehirleşmenin tarım arazileri ile ters orantılı bir ilişki gösterdiğini ortaya koymaktadır. Ayrıca, Sulanan tarım arazisi (% toplam tarım arazisi) ile Kentsel nüfus (% toplam nüfus) arasındaki korelasyon katsayısı 0.951 olup, bu iki değişken arasında güçlü bir pozitif ilişki mevcuttur. Bu sonuç, şehirleşme oranındaki artışın, sulama altyapısının gelişmiş olduğu bölgelerle ilişkili olabileceğini düşündürmektedir. Sulanan tarım alanlarının oranı ile şehirleşme oranı arasında güçlü bir pozitif ilişki bulunmaktadır. Bu, şehirleşmenin artışının sulama altyapısının gelişmiş olduğu bölgelerle ilişkili olabileceğini göstermektedir.

Yapılan analizler, veri setinde çoklu doğrusallık probleminin varlığını işaret etmektedir. Bu durum, modelde kullanılan değişkenler arasında yüksek doğrusal bağımlılık olduğunu göstermekte ve bu bağımlılık tahminlerin güvenilirliğini ve modelin genelleştirme kapasitesini olumsuz yönde etkileyebilmektedir. Çoklu doğrusallık problemi varlığı, özellikle regresyon gibi doğrusal modellerde tahmin edici değişkenlerin katsayılarının istatistiksel anlamlılığını düşürebilir ve modelin performansını azaltabilecektir. Bu nedenle, modelleme sürecinde bu sorunu gidermek için uygun yöntemler uygulanmalıdır. Bu çalışmada bu problemin üstesinden gelebilmek için Ana Bileşen Analizi (Principal Component Analysis)- PCA uygulanmıştır.

2.7.2. Ana Bileşen Analizi (PCA)

Ana Bileşen Analizi (PCA), çoklu doğrusallık problemini çözmek için kullanılan etkili bir yöntemdir. Bu yöntem, yüksek korelasyona sahip değişkenleri birleştirerek daha az sayıda, ancak bağımsız ve anlamlı bileşenler (principal components) oluşturmaktadır. Bu bileşenler, doğrusal bağımlılığı ortadan kaldırarak modelin yalnızca bağımsız değişkenler üzerinden çalışmasına olanak tanımaktadır. PCA, özellikle veri setinde fazla sayıda değişken olduğunda, modelin performansını artırma ve karmaşıklığını azaltma açısından tercih edilen bir tekniktir (Jolliffe, 2002).

PCA'nın öne çıkan avantajları şunlardır:

- 1. Doğrusal bağımlılığı azaltma:** PCA, çoklu doğrusallık problemini tamamen ortadan kaldırarak regresyon modellerinde katsayıların istikrarını artırır ve tahmin edilebilirliği güçlendirmektedir.

2. Boyut azaltma: Çok sayıda değişken yerine, bu değişkenlerin kombinasyonlarından oluşturulan daha az sayıda bileşen kullanılmaktadır. Bu durum, modelin daha sade, etkili ve hesaplama açısından verimli hale gelmesini sağlamaktadır.

Bununla birlikte, PCA'nın önemli bir sınırlaması da bulunmaktadır. Elde edilen bileşenler, orijinal değişkenlerin doğrusal kombinasyonlarından oluşturulduğu için yorumlanabilirliği zorlaştırmaktadır. Bu nedenle, analiz sonuçlarının bağlamına uygun bir şekilde yorumlanması ve uygulama alanına göre karar verilmesi önem arz etmektedir (Jolliffe, 2002).


Korelasyon analizi sonucu belirlenen 6 değişkene PCA analizi uygulanmıştır. PCA analiz sonuçları Tablo 5'de verilmiştir.

Tablo 5: PCA Analiz Sonuçları

Temel Bileşen	Açıklanan Varyans Oranı
PC1	0,900382396
PC2	0,041947079
PC3	0,030010029
PC4	0,018823253
PC5	0,007221162
PC6	0,001616081

Tablo 5 incelendiğinde, birinci temel bileşen (PC1) toplam varyansın %90,04'ünü açıklayarak veri setindeki bilginin büyük bir kısmını temsil etmektedir. Bu durum, değişkenler arasında yüksek doğrusal ilişki (çoklu doğrusallık problemi) olduğunu ve verinin büyük ölçüde tek bir boyutta özetlenebildiğini göstermektedir. İkinci temel bileşen (PC2) varyansın %4,19'unu açıklarken, üçüncü ve dördüncü bileşenler (PC3 ve PC4) sırasıyla %3,00 ve %1,88 gibi düşük oranlarda katkı sağlamaktadır. Beşinci ve altıncı bileşenlerin katkısı (%0,72 ve %0,16) ihmal edilebilir seviyededir. Bu sonuçlar, modelin daha sade ve etkili hale getirilmesi için yalnızca PC1 ve gerekirse PC2 bileşenlerinin kullanılmasının yeterli olduğunu göstermektedir. Diğer bileşenler, varyansa anlamlı bir katkı sağlamadığından, analiz veya modelleme sürecinde dikkate alınmayabilmektedir. Bu durum, boyut indirgeme ve çoklu doğrusallık problemini ortadan kaldırarak modelin performansını artırmakta ve hesaplama yükünü azaltmaktadır.

Aşağıdaki grafikte, PCA sonucunda elde edilen temel bileşenlerin açıklanan varyans oranları ile kümülatif varyans değerleri görselleştirilmiştir. Şekil 19'da da görüleceği üzere, birinci bileşen (PC1) varyansın büyük bir kısmını açıklarken, diğer bileşenlerin katkısı nispeten düşük kalmaktadır. Bu durum, analiz sürecinde yalnızca birkaç bileşenin kullanılmasının yeterli olabileceğini göstermektedir.



Şekil 19: PCA Temel Bileşenlerinin Açıklanan Varyans Oranları

PCA sonuçlarına göre ilk bileşen (PC1) toplam varyansın %90'ını açıklamakta ve diğer bileşenlerin katkısı oldukça düşük kalmaktadır. PC1'de öne çıkan değişkenler, yüksek yük değerlerine sahip olan değişkenlerdir. Bu değerler, bileşenin hangi değişkenlerden en fazla etkilendiğini göstermektedir. Tablo 6, Temel Bileşen Analizi (PCA) sonucunda elde edilen temel bileşenlerin, değişkenler üzerindeki yük değerlerini göstermektedir. Bu yükler, her bir temel bileşenin veri setindeki değişkenler ile olan ilişkisini ve katkı düzeyini ifade etmektedir.

Tablo 6: Temel Bileşenler ve Değişken Katkıları

Temel Bileşen	Değişken	Yük Değeri
PC1	Tarım arazisi (% arazi alanı)	0,411
	Tarım, ormancılık ve balıkçılık, katma değer (% GSYİH)	0,402
	Tarımda istihdam (% toplam istihdam)	0,408
PC2	Kentsel nüfus (% toplam nüfus)	-0,421
	Tarım arazisi (% arazi alanı)	-0,461
	Sulanan tarım arazisi (% toplam tarım arazisi)	0,419
PC3	Yıllık tatlı su çekimi, tarım (% toplam tatlı su çekimi)	-0,708
	Tarım, ormancılık ve balıkçılık, katma değer (% GSYİH)	0,704
	Yıllık tatlı su çekimi, tarım (% toplam tatlı su çekimi)	0,477
PC4	Sulanan tarım arazisi (% toplam tarım arazisi)	0,264
	Tarımda istihdam (% toplam istihdam)	0,671
	Tarım, ormancılık ve balıkçılık, katma değer (% GSYİH)	-0,573
PC5	Yıllık tatlı su çekimi, tarım (% toplam tatlı su çekimi)	0,334
PC6	Kentsel nüfus (% toplam nüfus)	-0,275

Bu çalışmada PC1 ve PC2 temel bileşenlerindeki değişkenler seçilerek girdi değişkeni olarak kullanılmıştır. Çünkü bu iki temel bileşen, veri setindeki toplam varyansın büyük bir kısmını açıklamakta ve modelin performansını optimize etmektedir. PC1 (Birinci Temel Bileşen), toplam varyansın %90,04'ünü açıklayarak en fazla bilgi taşıyan bileşen olarak öne

çıkılmaktadır. Bu bileşen, özellikle tarım arazisi (% arazi alanı), tarım, ormancılık ve balıkçılık, katma değer (% GSYİH) ve tarımda istihdam (% toplam istihdam) değişkenlerinde yüksek pozitif yük değerleri taşımaktadır. Bu durum, tarımsal faaliyetlerin ekonomik katkısı ve istihdam boyutunun tarım kredilerinin tahmininde önemli bir rol oynadığını göstermektedir. Ayrıca, PC1’de kentsel nüfus (% toplam nüfus) değişkeninin negatif yük değeri taşıması, şehirleşmenin tarım faaliyetleri ve dolayısıyla tarımsal kredi ihtiyacı üzerindeki ters yönlü etkisini ortaya koymaktadır.

PC2 (İkinci Temel Bileşen) ise toplam varyansın %4,19’unu açıklamakta olup, sulanan tarım arazisi (% toplam tarım alanı) ve yıllık tatlı su çekimi, tarım (% toplam tatlı su çekimi) gibi değişkenlerde belirgin yük değerlerine sahiptir. Bu durum, tarımsal üretimde su kaynaklarının kullanımı ve sulama altyapısının, tarımsal kredi talebini etkileyen önemli unsurlar arasında yer aldığını göstermektedir.

Sonuç olarak, PC1 ve PC2 temel bileşenleri, değişkenler arasındaki khandin büyük bir kısmını temsil etmekte ve modelin daha az sayıda değişkenle daha yüksek performans göstermesini sağlamaktadır. PC1, tarımsal faaliyetlerin ekonomik ve istihdam boyutunu açıklarken, PC2 tarımsal üretimde su kullanımı ve altyapı faktörlerini vurgulamaktadır. Bu iki bileşenin seçimi hem modelin doğruluğunu artırmakta hem de analiz sürecini daha etkili ve hesaplama açısından verimli hale getirmektedir.

2.7.3. Tanımlayıcı İstatistikler

Bir zaman serisinde tanımlayıcı istatistiklerin (ortalama, standart sapma, minimum, maksimum, çarpıklık ve basıklık) hesaplanması, serinin temel özelliklerini anlamak ve analiz etmek için kritik öneme sahiptir. Ortalama, serinin genel eğilimini ve merkezini ifade ederken, standart sapma dalgalanma derecesini ve volatilitiyi ortaya koymaktadır. Minimum ve maksimum değerler serinin aralığını ve uç noktalarını göstermektedir. Çarpıklık, serinin simetrik olup olmadığını belirleyerek eğilimlerin yönünü anlamayı sağlamakta, basıklık ise aşırı uç olayların sıklığını değerlendirmektedir. Bu istatistikler, verinin özetlenmesi, anormalliklerin tespiti, uygun model seçimi ve seriler arası karşılaştırma için temel bir zemin sunmaktadır. Tablo 7’de çalışmada kullanılan değişkenlerin tanımlayıcı istatistik değerleri verilmiştir.

Tablo 7: Tanımlayıcı İstatistikler

Değişkenler	Ortalama	Min	Max	St Sapma	Çarpıklık	Basıklık
Tarım arazisi (% arazi alanı)	50,8746	49,0054	53,5621	1,6050	0,6102	-1,2419
Tarım, ormancılık ve balıkçılık, katma değer (% GSYİH)	7,6670	5,5338	10,1908	1,3997	0,3234	-1,1275

Tarımda istihdam (% toplam istihdam)	24,1161	16,6597	37,5914	6,1374	1,0251	0,1370
Kentsel nüfus (% toplam nüfus)	71,2080	64,7410	77,0220	3,7382	-0,1306	-1,2097
Yıllık tatlı su çekimi, tarım (% toplam tatlı su çekimi)	84,4894	76,2533	87,5717	3,0611	-1,2245	0,7803
Sulanan tarım arazisi (% toplam tarım arazisi)	13,3320	12,6345	14,0303	0,4466	-0,4615	-1,2470
Tarım Kredileri	970,4079	73,9089	3451,6861	838,3611	1,0583	1,5596

Tablo 7’de verileri tanımlayıcı istatistikler incelendiğinde, her bir değişkenin ortalama değerleri genel eğilimleri yansıtırken, minimum ve maksimum değerler veri aralığının genişliğine işaret etmektedir. Standart sapma değerleri, değişkenin ortalama etrafındaki yayılım derecesini gösterirken, çarpıklık ve basıklık istatistikleri dağılımın biçimini (normalden sapma yönünü ve sivriliğini) ortaya koymaktadır.

Tarım arazisi (% arazi alanı), ortalama değer (%50,87) nispeten dar bir aralıkta (49,01 – 53,56) seyretmesi, bu göstergede görece istikrarlı bir yapı olduğunu göstermektedir. Standart sapma (1,61) düşük sayılabilecek düzeydedir. Çarpıklığın pozitif (0,61) olması dağılımın sağa eğimli olduğunu, ancak bu eğimin güçlü olmadığını göstermektedir. Basıklığın (-1,24) negatif değeri, dağılımın normalden daha basık (platykurtic) bir yapıda olduğunu yansıtmaktadır.

Tarım, ormancılık ve balıkçılık, katma değer (% GSYİH) verileri incelendiğinde; ortalama yaklaşık %7,67 düzeyindedir. Minimum (%5,53) ve maksimum (%10,19) değerler arasında makul bir genişlik söz konusudur. Standart sapma (1,40) orta düzeyde dalgalanmaya işaret ederken, pozitif çarpıklık (0,32) dağılımın hafifçe sağa doğru uzadığını göstermektedir. Negatif basıklık (-1,13) dağılımın normalden daha yayvan olduğunu ima etmektedir.

Tarımda istihdam (% toplam istihdam verilerinin ortalaması (%24,12) incelenen dönem içinde tarım sektörünün toplam istihdam içindeki payının önemli olduğunu göstermektedir. Değerler 16,66 ile 37,59 arasında değişerek geniş bir aralık sunar, standart sapma (6,14) ise görece yüksek bir oynaklığa işaret etmektedir. Pozitif çarpıklık (1,03) yüksek değerlerin dağılımda seyrek ama etkili olduğunu, basıklığının (0,14) düşük pozitifliği ise dağılımın normal dağılıma yakın ancak hafifçe sivrileşmiş olabileceğini göstermektedir.

Kentsel nüfus (% toplam nüfus) verileri incelendiğinde ortalama (%71,21) kentsel nüfus oranının yüksek olduğu görülmektedir. Veriler dar bir bantta (64,74–77,02) yoğunlaşmış olup standart sapma (3,74) orta düzeydedir. Negatif çarpıklık (-0,13), dağılımın sola doğru hafif eğimli olduğunu, yani büyük ölçüde ortalamanın üzerinde değerlerin daha yoğun olduğunu göstermektedir. Negatif basıklık (-1,21) ise dağılımın basık bir yapıda olduğunu, dolayısıyla aşırı uç değerlerin görece az olduğunu ortaya çıkarmıştır.

Yıllık tatlı su çekimi, tarım (% toplam tatlı su çekimi) verilerinin tanımlayıcı istatistiklerine göre; ortalama %84,49 ile oldukça yüksek bir düzeydedir. Verilerin (76,25 – 87,57) arasında değişmesi bu oranlarda da görece sınırlı bir varyasyon olduğunu ortaya koymaktadır. Standart sapma (3,06) ılımlı bir oynaklık gösterirken, negatif çarpıklık (-1,22) dağılımın sola doğru uzadığını, pozitif basıklık (0,78) ise dağılımın sivrileşerek bazı değerlere doğru yoğunlaştığını göstermektedir.

Sulanan tarım arazisi (% toplam tarım arazisi) verileri için ortalama (%13,33) düşük bir varyasyonla (12,63 – 14,03) sınırlı bir aralıkta yoğunlaşmaktadır. Standart sapma (0,45) oldukça düşüktür ve bu değer istikrarlı bir dağılıma işaret ettiğini söylemek mümkündür. Negatif çarpıklık (-0,46) sola doğru hafif bir eğim, negatif basıklık (-1,25) ise dağılımın yayvan bir biçimde yayıldığını göstermektedir.

Tarım Kredileri verilerinin tanımlayıcı istatistiklerine göre; bu değişkenin ortalama değeri 970,41 iken, minimum 73,91 ve maksimum 3451,69 ile oldukça geniş bir aralığa sahiptir. Standart sapmanın 838,36 olması, değerlerin ortalamadan büyük sapmalar gösterebildiğini ve önemli bir değişkenlik olduğu görülmektedir. Pozitif çarpıklık (1,06), yüksek birkaç değer dağılımı sağa doğru çektiğini, böylelikle çoğu gözlemin ortalamadan daha düşük fakat birkaç gözlemin oldukça yüksek kredi değerlerine sahip olduğunu göstermektedir. Pozitif basıklık (1,56) dağılımın belirli noktalarda yoğunlaştığını, yani yüksek değerlerin istatistiksel olarak anlamlı düzeyde uç değer yarattığını düşündürmektedir.

Genel olarak, söz konusu değişkenler arasında tarım kredileri, en yüksek oynaklık ve uç değer potansiyeline sahip görünüp daha asimetric bir dağılım sergilemektedir. Diğer değişkenler ise genellikle dar aralıklarda sıkışmış, orta düzeyde veya düşük oynaklık sergileyen, kimi zaman hafif çarpık veya basık bir dağılıma sahip olup, istikrarlı yapılarıyla dikkat çekmektedir. Bu durum, tarım sektörünün farklı boyutlarının (arazi kullanımı, istihdam, su kullanımı, kentsel nüfus payı) görece sabit bir yapıda olduğunu, ancak tarım kredisi kullanımının daha dinamik, farklı dönemler ve koşullara göre büyük değişkenlikler gösterebileceğini işaret etmektedir.

2.8. VERİ NORMALİZASYONU VE ÖLÇEKLEME

Normalizasyon, bir veri setindeki değişkenlerin farklı ölçek ve birimlerden kaynaklanan etkilerini gidermek amacıyla, değerlerin belirli bir ölçeğe (genellikle 0 ile 1 arasında) dönüştürülmesi işlemidir (Han vd., 2011). Bu yöntem, özellikle mesafeye dayalı algoritmalar (örneğin, KNN, K-Means, ve SVM) ile çalışırken, her bir değişkenin eşit öneme sahip olmasını sağlamak ve modelin öğrenme performansını artırmak için kritik bir adım olarak kabul

edilmektedir (Patro & Sahu, 2015). Farklı ölçeklerdeki değişkenler, modelin sonuçlarını yanıltabilir ve yüksek ölçekli değişkenlerin düşük ölçekli olanlara kıyasla daha fazla ağırlığa sahip olmasına neden olabilmektedir. Normalizasyon, bu sorunun önüne geçerek daha adil bir değerlendirme sağlamaktadır.

Makine öğrenmesi algoritmalarında, özellikle Euclidean mesafesi gibi metrikler kullanıldığında, farklı birimlere sahip değişkenler modelin ağırlıklandırmasını bozabilmektedir. Örneğin, bir değişkenin değeri 1000 birim ölçeğinde iken diğer bir değişkenin değeri 0-1 arasında değişiyorsa, model büyük ölçekli değişkene daha fazla öncelik verebilmektedir. Bu durum, küçük ölçekli ancak önemli olan değişkenlerin etkisini azaltmakta ve modelin öğrenme sürecini yanıltıcı hale getirmektedir (Han vd., 2011). Normalizasyon, tüm değişkenleri aynı ölçeğe getirerek bu sorunu ortadan kaldırmakta ve modelin doğru ilişkileri öğrenmesini sağlamaktadır. Ayrıca, normalizasyon verinin belirli bir dağılım varsayımı gerektiren algoritmalarda (örneğin, yapay sinir ağları) daha iyi performans göstermesine olanak tanımaktadır. Özellikle optimizasyon süreçlerinde, normalleştirilmiş veriler, modelin daha hızlı öğrenmesine ve optimizasyon algoritmalarının daha etkili bir şekilde çalışmasına katkıda bulunmaktadır (Patro & Sahu, 2015). Sonuç olarak, normalizasyon, makine öğrenmesi projelerinde veri setinin farklı ölçeklerden kaynaklanan sorunlarını gidererek modelin doğruluğunu ve genel performansını artırmak için vazgeçilmez bir süreçtir. Bu yöntem, modelin daha genellenebilir ve güvenilir sonuçlar üretmesini sağlamaktadır.

Makine öğrenmesi modellerinde, verilerin 0-1 yerine 0.05 ile 0.95 arasında normalize edilmesi, model performansını artırmak ve öğrenme sürecini daha kararlı hale getirmek için tercih edilmektedir. Bunun temel nedenlerinden biri, uç değerlerin model üzerindeki olumsuz etkilerini azaltmaktır. Özellikle, yapay sinir ağlarında sigmoid veya tanh gibi aktivasyon fonksiyonları kullanıldığında, girişlerin tam 0 veya 1 olması gradyanların küçülmesine ve "vanishing gradient" (kaybolan gradyan) problemine yol açabilmektedir. 0.05 ile 0.95 aralığında normalizasyon, bu tür problemlerin önüne geçerek modelin daha etkili bir şekilde öğrenmesini sağlamaktadır.

Ayrıca, 0 ve 1 değerleri, log-loss (lojistik kayıp) gibi kayıp fonksiyonlarında matematiksel sorunlara neden olabilmektedir. Özellikle, modelin çıktısının tam 0 veya tam 1 olması durumunda, logaritmik fonksiyon tanımsız hale gelebilmekte ve bu da numerik kararsızlıklara yol açabilmektedir. 0.05 ile 0.95 arasında bir normalizasyon aralığı, bu tür sayısal istikrarsızlıkları önlemekte ve modelin daha kararlı bir şekilde çalışmasına olanak tanımaktadır. Bununla birlikte, bu normalizasyon aralığı, algoritmaların aşırı uç değerlere duyarlılığını azaltarak daha dengeli bir model oluşturulmasını desteklemektedir. 0.05 ve 0.95

gibi sınırlarla yapılan normalizasyon, tahmin edilen olasılıkların daha gerçekçi bir aralıkta kalmasını sağlamak ve modelin aşırı güvenli (tam 0 veya tam 1 tahmin eden) sonuçlar üretmesini önlemektedir. Bu durum, özellikle lojistik regresyon veya derin öğrenme modellerinde önemli bir avantaj sunmaktadır. Sonuç olarak, 0,05 ile 0,95 arasında normalizasyon, uç değerlerin etkisini azaltmak, numerik kararlılığı artırmak ve daha genelleştirilebilir modeller oluşturmak için kritik bir stratejidir. Bu yöntem, modelin öğrenme kapasitesini artırırken, veri dağılımını daha doğal bir şekilde yansıtarak hem eğitim hem de tahmin süreçlerinde daha güvenilir sonuçlar elde edilmesini sağlamaktadır. Bu nedenle, bu çalışmada değişken değerleri 0,05-0,95 aralığında normalize edilmiştir. Denklem 22’de 0,05-0,95 aralığı normalizasyon formülü verilmiştir.

$$X_{norm} = 0.05 + \frac{(X - X_{min})}{(X_{max} - x_{min})} \times (0.95 - 0.05) \quad (23)$$

Değişkenler:

- X : Orijinal veri değeri
- X_{min} : Verinin minimum değeri
- X_{max} : Verinin maksimum değeri
- X_{norm} : 0,05 ile 0,95 arasında normalize edilmiş değer

Tarım kredilerinin tahmini için 23 yıllık veri seti kullanılmış olup, analiz süreci %80 eğitim- %20 test oranında veri bölme yöntemi ve 3 katlı çapraz doğrulama ile gerçekleştirilmiştir. Bu süreç, modelin genelleme performansını artırmak, aşırı öğrenme (overfitting) riskini minimize etmek ve sonuçların güvenilirliğini sağlamak amacıyla uygulanmıştır.

Veri seti, modelin eğitimi ve test edilmesi amacıyla ikiye ayrılmıştır. Bu bağlamda, verinin %80’lik kısmı eğitim seti olarak kullanılmış, geri kalan %20’lik kısmı ise test seti olarak ayrılmıştır. Eğitim seti, modellerin bağımlı değişken (tarım kredileri) ile bağımsız değişkenler (tarım arazisi oranı, tarımsal katma değer, tarımda istihdam, sulanan tarım arazisi, tarımsal tatlı su kullanımı ve kentsel nüfus oranı) arasındaki ilişkileri öğrenmesini sağlamak amacıyla kullanılmıştır. Test seti ise, eğitim sürecinde öğrenilen bu ilişkilerin modele daha önce gösterilmemiş veriler üzerinde ne ölçüde doğru tahminlerde bulunacağını değerlendirmek için uygulanmıştır. Bu süreç, modelin genelleme kapasitesini ölçmek adına kritik bir adımdır.

Bu çalışmada, tarım kredilerinin tahmini gibi ekonomik açıdan önemli bir problem üzerinde, farklı makine öğrenmesi algoritmalarının performansı karşılaştırmalı olarak değerlendirilmiştir. Bu bağlamda, Gauss Süreç Regresyonu (GPR), Yapay Sinir Ağları (YSA), Destek Vektör Regresyonu (SVR), Karar Ağaçları ve Topluluk Öğrenme Yöntemleri (EL)

kullanılmıştır. Bu algoritmaların seçimi, veri setindeki doğrusal olmayan ilişkilerin modellenenebilmesi ve küçük veri setlerinde yüksek genelleme kapasitesine sahip olmaları gibi güçlü yönlerine dayanmaktadır. Ayrıca, istatistiksel yöntem olarak çoklu doğrusal regresyon yöntemi uygulanmış olup, sonuçları diğer yöntemlerle karşılaştırılmıştır.

Çalışmada kullanılan veri seti, 2000-2022 yılları arasını kapsayan tarımsal kredi verilerini içerirken, bağımsız değişkenler arasında tarım arazisi, katma değer, tarımda istihdam, sulanan tarım arazisi, tatlı su çekimi ve kentsel nüfus oranı gibi tarımsal ve ekonomik faktörler yer almıştır. Bu veri seti, değişkenlerin hem doğrusal hem de doğrusal olmayan ilişkiler içerdiği bir yapı sunduğu için, farklı algoritmaların performanslarının kapsamlı bir şekilde karşılaştırılmasına olanak tanımıştır. Ayrıca, veri setinde eksik değerlerin tamamlanması ve normalizasyon gibi ön işleme adımları, modellerin doğruluğunu artırmak için dikkatlice uygulanmıştır.

Sonuç olarak, bu süreç, farklı makine öğrenmesi algoritmalarının tarım kredileri gibi ekonomik problemlerde nasıl uygulanabileceğini göstermiştir.

ÜÇÜNCÜ BÖLÜM

3. BULGULAR

Bu bölümde, tarım kredileri tahminine yönelik olarak gerçekleştirilen modelleme çalışmasının bulguları ayrıntılı olarak sunulmaktadır. Çalışmanın temel amacı, tarım kredilerinin tahmininde en uygun modelin belirlenmesi ve bu modellerin performanslarının karşılaştırmalı olarak değerlendirilmesidir. Tahmin sürecinde kullanılan girdi değişkenleri, tarımsal faaliyetlerin ekonomik, sosyal ve altyapısal boyutlarını temsil eden unsurlardan oluşmaktadır. Bu bağlamda tarımsal alan (% toplam arazi), tarım, ormancılık ve balıkçılık katma değeri (% GSYH), tarımda istihdam (% toplam istihdam), sulanan tarım arazisi (% toplam tarım alanı), yıllık tatlı su çekimi, tarım (% toplam tatlı su çekimi) ve kentsel nüfus (% toplam nüfus) değişkenleri, modelleme sürecinde bağımsız değişkenler (girdiler) olarak kullanılmıştır. Bağımlı değişken (çıktı) ise tarım kredilerinin miktarıdır.

Veri seti, 23 yıllık bir zaman serisinden oluşmakta olup, küçük veri setleriyle çalışmanın getirdiği kısıtlar göz önünde bulundurulmuştur. Küçük veri setlerinde doğrulama süreçlerinin önemi dikkate alınarak, çalışmada 3 katlı çapraz doğrulama (3-Fold Cross Validation) yöntemi kullanılmıştır. Çapraz doğrulama, model performansının yalnızca tek bir eğitim-test bölünmesi üzerinden değil, farklı alt veri kümeleri üzerinde tekrarlı olarak test edilmesini sağlamış ve sonuçların tutarlılığını artırmıştır. Bu yöntem, küçük veri setlerinde sıklıkla karşılaşılan overfitting (aşırı öğrenme) riskinin azaltılmasına katkı sağlamıştır.

Bulguların değerlendirilmesinde, modellerin performansı RMSE (Kök Ortalama Kare Hata), MSE (Ortalama Kare Hata), MAE (Ortalama Mutlak Hata) ve R^2 (Determinasyon Katsayısı) gibi yaygın metrikler kullanılarak ölçülmüştür. Bu metrikler aşağıdaki gibi özetlenebilir:

R^2 (Determinasyon Katsayısı): Modelin bağımsız değişkenlerin bağımlı değişken üzerindeki açıklayıcılık gücünü ifade etmektedir. 1'e yakın R^2 değeri, modelin veriyi başarılı bir şekilde açıkladığını göstermektedir.

RMSE (Kök Ortalama Kare Hata): Tahmin edilen değerler ile gerçek değerler arasındaki hata büyüklüğünü göstermektedir. Düşük RMSE değeri, modelin tahmin hatasının küçük olduğunu belirtmektedir.

MAE (Ortalama Mutlak Hata): Hata değerlerinin mutlak ortalaması olup, gözlenen değerlerden tahmin edilen değerlere olan sapmayı ifade etmektedir.

Çalışmada kullanılan modeller; Gaussian Process Regression (GPR), Destek Vektör Makineleri (SVM), Yapay Sinir Ağları (Neural Network), Karar Ağaçları (Tree) ve Ensemble (EL) ve Çoklu Doğrusal Regresyon (MLR) modellerinden oluşmaktadır. Bu modeller, farklı algoritmalar kullanarak verideki ilişkileri analiz etmiş ve tahmin sonuçları üzerinden karşılaştırılmıştır.

Analizlerde kullanılan modellerin performansını değerlendirmek amacıyla gerekli hesaplamalar MATLAB 2020 yazılımı kullanılarak gerçekleştirilmiştir. Hesaplamalar, güçlü işlem kapasitesine sahip bir MacBook Pro M3 işlemcili bilgisayar aracılığıyla yapılmıştır. M3 işlemci, yüksek hesaplama hızları ve optimizasyon yetenekleriyle model eğitim ve test süreçlerini hızlandırarak, büyük veri setlerine kıyasla daha sınırlı olan çalışma veri setinde dahi yüksek performanslı sonuçlar elde edilmesini sağlamıştır. Donanım ve yazılım altyapısının uyumu, analizlerin doğruluk ve güvenilirlik düzeyini artırmış, özellikle karmaşık modellerin (örneğin Yapay Sinir Ağları ve Ensemble yöntemleri) daha kısa sürede çalıştırılmasına olanak tanımıştır. Bu durum, çalışmanın tekrarlanabilirliğini ve elde edilen bulguların sağlamlığını desteklemektedir.

Modelleme sürecinde, özellikle Gaussian Process Regression (GPR) ve Ensemble modellerinin test aşamasında yüksek performans gösterdiği gözlemlenmiştir. Bu modeller, hem düşük hata değerleri (RMSE ve MAE) hem de yüksek R^2 değerleri ile diğer modellerden ayrılmıştır. Küçük veri seti kullanılmış olmasına rağmen, çapraz doğrulama ile doğrulanan bu bulgular, modellerin genelleme kapasitesinin yüksek olduğunu göstermektedir.

Bu bölümün ilerleyen kısımlarında, uygulanan her bir modelin eğitim ve test aşamasında elde edilen sonuçları, performans metrikleri üzerinden ayrıntılı olarak sunulmaktadır. Bulgular, tablolar ve görsellerle desteklenerek, modellerin karşılaştırmalı analizine yer verilmiştir.

3.1. GAUSS SÜRECİ REGRESYONU (GPR) YÖNTEMİNİN BULGULARI

Geliştirilen GPR modeli, tarım kredileri tahmini için uygulanan modeller arasında en yüksek performansı göstermiştir. Test aşamasında elde edilen RMSE (0,0545) değeri, modelin tahmin hatasının oldukça düşük olduğunu ortaya koyarken; R^2 (0,9110) değeri, GPR'nin bağımlı değişken olan tarım kredisi miktarındaki varyansın %91'ini açıklayabildiğini göstermektedir. Bu bulgular, GPR modelinin karmaşık ve doğrusal olmayan ilişkileri başarılı bir şekilde modelleyebildiğini ve küçük veri setlerinde yüksek genelleme kapasitesi sunduğunu ortaya koymaktadır.

GPR, veri noktalarının arasındaki ilişkileri olasılıksal bir çerçevede ele alarak tahmin yapan parametrik olmayan bir regresyon yöntemidir (Rasmussen & Williams, 2006). Bu yöntem, özellikle küçük veri setlerinde doğrusal olmayan ve karmaşık yapıları öğrenme kapasitesi sayesinde öne çıkmaktadır. GPR, küçük ve sınırlı veri setlerinde diğer makine öğrenmesi yöntemlerine kıyasla genellikle daha başarılı sonuçlar vermektedir. Küçük veri setlerinde klasik regresyon yöntemleri (Linear Regression, SVR) genelleme hatası ile karşılaşırken, GPR kernel fonksiyonları aracılığıyla daha esnek bir yapıda çalışarak veriyi yüksek doğrulukla öğrenebilmektedir. Literatürde GPR'nin özellikle küçük veri setleri üzerinde yüksek performans gösterdiği çeşitli çalışmalarda vurgulanmaktadır (Rasmussen & Williams, 2006; Bishop, 2006). GPR, kernel trick kullanarak doğrusal olmayan ilişkileri modele dahil edebilir ve bu sayede karmaşık ilişkileri doğru bir şekilde modelleyebilmektedir. Bu çalışmada da tarımsal faaliyetler ve kredi tahmini arasındaki doğrusal olmayan yapının GPR tarafından etkili bir şekilde öğrenildiği görülmektedir. Williams ve Barber (1998) GPR'nin esnek yapısı sayesinde karmaşık veri setlerinde yüksek doğruluk sağlayabileceğini ve genelleme kapasitesinin güçlü olduğunu belirtmişlerdir. GPR'nin bir diğer önemli avantajı, tahminler sırasında belirsizlik ölçümlerini de sağlayabilmesidir. Bu, modelin yalnızca tahminler üretmekle kalmayıp aynı zamanda tahminlerinin güvenilirliğini de ortaya koymasını sağlamaktadır (Rasmussen & Williams, 2006). Bu özellik, özellikle ekonomik tahminler gibi karar destek süreçlerinde kritik öneme sahiptir.

Tarım kredileri tahmini için uygulanan GPR modeli, test aşamasında en düşük RMSE değeri (0,0545) ve en yüksek R^2 değeri (0,9110) ile diğer modellere belirgin bir üstünlük sağlamıştır. Model sonuçları Tablo 8'de verilmiştir.

Tablo 8: GPR Modeli Performans Ölçütleri

Aşamalar	Performans Ölçütleri			
	RMSE	MSE	R^2	MAE
Eğitim Aşaması	0,1846	0,0341	0,4482	0,1197
Test Aşaması	0,0545	0,0030	0,9110	0,0446

Bu performans, GPR'nin verinin altında yatan karmaşık yapıyı yakalama yeteneği ile açıklanabilmektedir. GPR, doğrusal olmayan ilişkileri modellenebilir hale getirirken, veri setindeki sınırlı gözlem sayısını da dikkate alarak aşırı öğrenme (overfitting) riskini minimize etmektedir. 3 katlı çapraz doğrulama yöntemi ile test edilen model, bu sayede genelleme kapasitesinin yüksek olduğunu ve rastlantısal performans artışından arındırıldığını göstermektedir. Küçük veri setlerinde çapraz doğrulama, model sonuçlarının güvenilirliğini artıran önemli bir adımdır (Kuhn & Johnson, 2013). Bu çalışmanın sonuçları, GPR'nin küçük

veri setlerinde yüksek doğruluklu tahminler elde edebilme yeteneğini bir kez daha kanıtlamaktadır. Sonuç olarak, Gaussian Process Regression (GPR) modeli, tarım kredisi tahmini için en başarılı model olarak belirlenmiştir. Test aşamasındaki yüksek R^2 ve düşük RMSE değerleri, modelin doğrusal olmayan yapıları etkili bir şekilde öğrenerek küçük veri setinde genelleme kapasitesini maksimum düzeyde kullandığını göstermektedir. GPR'nin esnek yapısı, küçük veri setlerinde sınırlı gözlem sayısına rağmen yüksek performans sağladığını destekleyen literatür bulguları ile tutarlıdır (Rasmussen & Williams, 2006; Bishop, 2006).

3.2. DESTEK VEKTÖR REGRESYONU (SVR) YÖNTEMİNİN BULGULARI

Tarım kredilerinin tahmin edilmesi amacıyla kullanılan SVR modeli, elde edilen bulgulara göre başarılı bir performans sergilemiştir. Modelin performansı, eğitim ve test aşamalarında incelenerek R^2 (Determinasyon Katsayısı) ve RMSE (Kök Ortalama Kare Hata) gibi değerlendirme metrikleri üzerinden analiz edilmiştir. Ayrıca modelin performansını artırmak amacıyla belirlenen hiperparametreler olan Box Constraint ($C = 164,142$), Kernel Scale (31), Epsilon ($\epsilon = 6,01$) ve Gaussian Kernel fonksiyonu kullanılmıştır.

SVR modeli, eğitim aşamasında R^2 değerinin 0,7200 olarak hesaplanması ile bağımsız değişkenlerin bağımlı değişken üzerindeki varyansın %72'sini açıklayabildiğini göstermektedir. Eğitim aşamasında elde edilen RMSE değeri ise 0,1314 olarak hesaplanmıştır. Bu değerler, modelin doğrusal olmayan karmaşık ilişkileri etkili bir şekilde öğrenebildiğini ve eğitim verisi üzerinde başarılı bir öğrenme süreci gerçekleştirdiğini ortaya koymaktadır. Gaussian Kernel fonksiyonunun kullanımı, modelin doğrusal olmayan yapıları esnek bir şekilde öğrenmesini sağlamış ve modelin eğitim performansını iyileştirmiştir. Ayrıca, Box Constraint parametresinin yüksek olması, modelin daha az hata toleransı ile çalışarak doğruluğunu artırmasına katkı sağlamıştır. Test aşamasında SVR modeli, R^2 değerinin 0,8150 olarak hesaplanması ile modelin bağımlı değişkendeki varyansın %81,5'ini açıkladığını göstermiştir. Bu yüksek R^2 değeri, modelin genelleme kapasitesinin güçlü olduğunu ve test verisi üzerinde tutarlı sonuçlar üretebildiğini ortaya koymaktadır. Test aşamasında elde edilen RMSE değeri ise 0,0786 olarak belirlenmiştir. Bu düşük hata oranı, SVR'nin doğruluk performansının yüksek olduğunu göstermektedir. Ancak, GPR modeline kıyasla test hatalarının biraz daha yüksek kalması, SVR'nin veri setindeki doğrusal olmayan ilişkileri öğrenebilmesine rağmen bazı kısıtlamalarının bulunduğunu göstermektedir. Geliştirilen SVR modelinin sonuçları Tablo 9'da verilmiştir.

Tablo 9: SVR Modeli Sonuçları

Aşamalar	Performans Ölçütleri			
	RMSE	MSE	R ²	MAE
Eğitim Aşaması	0,1315	0,0173	0,7200	0,0848
Test Aşaması	0,0787	0,0062	0,8150	0,0479

SVR modelinin bu performansı, özellikle küçük veri setlerinde doğrusal olmayan yapıları etkili bir şekilde modelleyebilmesi ve genelleme kapasitesinin yüksek olması ile açıklanabilmektedir. Literatürde SVR'nin küçük ve orta büyüklükteki veri setlerinde başarılı sonuçlar verdiği ve karmaşık ilişkileri doğru bir şekilde öğrenebildiği ifade edilmektedir (Smola & Schölkopf, 2004). Gaussian Kernel kullanımı, SVR'nin doğrusal olmayan ilişkileri başarıyla modellemesini sağlamış ve bu çalışmada elde edilen yüksek R² değerleriyle bu durum bir kez daha kanıtlanmıştır. Ayrıca, Box Constraint ve Epsilon parametrelerinin optimize edilmesi, modelin aşırı öğrenme (overfitting) riskini minimize ederek genelleme performansını artırmıştır. Küçük veri setlerinde bu tür parametrik olmayan yöntemlerin kullanımı, doğruluk performansını önemli ölçüde iyileştirmektedir (Drucker vd., 1997).

Sonuç olarak, SVR modeli, test aşamasında elde edilen R² = 0,8150 ve RMSE = 0,0786 değerleri ile tarım kredilerinin tahmininde başarılı bir performans sergilemiştir. Modelin genelleme kapasitesi yüksek olmakla birlikte, Gaussian Process Regression (GPR) modeline kıyasla hata oranlarının daha yüksek olması, veri setindeki doğrusal olmayan yapının SVR tarafından tam olarak öğrenilemediğini göstermektedir. Bununla birlikte, SVR modeli küçük veri setlerinde güçlü bir alternatif olarak öne çıkmakta ve tarım kredisi tahmininde kullanılabilecek güvenilir bir yöntem olduğunu ortaya koymaktadır.

3.3. KARAR AĞACI YÖNTEMİNİN BULGULARI

Tarım kredilerinin tahmini amacıyla uygulanan Karar Ağacı (Decision Tree) modeli, test aşamasında elde edilen R² = 0,7346 ve RMSE = 0,0942 değerleriyle orta düzeyde bir performans sergilemiştir. Modelin açıklayıcılık gücü, bağımsız değişkenlerin bağımlı değişkendeki varyansın %73,5'ini açıklayabildiğini göstermektedir. Ancak test aşamasındaki RMSE değerinin yüksek olması, modelin tahmin hatalarının diğer modellerle kıyaslandığında daha fazla olduğunu ve genelleme performansının sınırlı kaldığını ortaya koymaktadır. Geliştirilen Karar Ağacı Modeline ait performans ölçütleri tablo 10'da verilmiştir.

Tablo 10: Karar Ağacı Modeli Performans Ölçütleri

Aşamalar	Performans Ölçütleri			
	RMSE	MSE	R2	MAE
Eğitim Aşaması	0,1876	0,0352	0,4302	0,1436
Test Aşaması	0,0942	0,0089	0,7346	0,0791

Karar Ağaçlarının bu sonucu, yöntemin sezgisel yapısı ve veri seti özelliklerine olan duyarlılığı ile ilişkilendirilebilmektedir. Karar Ağaçları, veri setlerini hiyerarşik bölme yöntemiyle alt kümelerle ayırarak karmaşık ilişkileri açıklama kapasitesine sahip olan parametrik olmayan bir yöntemdir (Breiman vd., 1984). Bu yöntem, doğrusal olmayan ilişkileri etkili bir şekilde öğrenebilir ve tahmin süreçlerinde hızlı çözümler sunmaktadır. Ancak literatürde de belirtildiği gibi, Karar Ağaçları özellikle küçük veri setlerinde aşırı öğrenme (overfitting) eğiliminde olabilir ve bu durum test aşamasında genelleme performansını sınırlayabilmektedir (Quinlan, 1996; Bishop, 2006). Bu çalışmada kullanılan 23 yıllık küçük veri seti, modelin bölme işlemleri sırasında verinin fazla parçalanmasına ve modelin aşırı uyum göstermesine neden olabilmektedir. Bu da test aşamasında hata oranının artmasına yol açmıştır.

Karar Ağaçlarının avantajlarından biri ise yorumlanabilirliği yüksek bir model olmasıdır. Literatürde karar ağaçlarının, karar verme süreçlerini açık bir şekilde görselleştirebilmesi nedeniyle özellikle ekonomik ve tarımsal tahminlerde yaygın olarak kullanıldığı ifade edilmektedir (Breiman vd., 1984; Quinlan, 1996). Bu çalışmada da Karar Ağacı modeli, girdi değişkenleri ile tarım kredileri arasındaki ilişkileri hiyerarşik bir yapı içinde açıklayabilmiş ve bağımsız değişkenlerin etkilerini değerlendirmek için sezgisel bir yöntem sunmuştur.

Ancak modelin test aşamasındaki performansı, GPR ve EL yöntemleri gibi alternatif modellere kıyasla daha düşük kalmıştır. GPR modeli, küçük veri setlerinde daha iyi genelleme kapasitesi sağlarken, Ensemble modelleri ise birden fazla modelin kombinasyonu sayesinde hata oranlarını azaltarak yüksek doğruluk sunmaktadır (Rasmussen & Williams, 2006; Breiman, 2001). Karar Ağacı modelinin performansını iyileştirmek için literatürde önerilen budama (pruning) tekniklerinin kullanılması, aşırı öğrenme riskinin azaltılması ve modelin genelleme kapasitesinin artırılması açısından önemli bir adım olabilecektir.

Sonuç olarak, Karar Ağacı modeli, tarım kredisi tahmininde kabul edilebilir bir performans göstermiş, ancak hata oranları ve açıklayıcılık gücü açısından GPR ve Ensemble modellerinin gerisinde kalmıştır. Bu bulgular, modelin hızlı ve yorumlanabilir bir çözüm sunduğunu, ancak küçük veri setlerinde aşırı öğrenme riskine karşı dikkatli bir şekilde yapılandırılması gerektiğini göstermektedir. Gelecekteki çalışmalarda, Karar Ağacı

modellerinin daha büyük veri setlerinde uygulanması ve budama teknikleri ile iyileştirilmesi, model performansını önemli ölçüde artırabilir.

3.4. TOPLULUK ÖĞRENMELERİ YÖNTEMİ BULGULARI

Bu çalışmada, tarım kredilerinin tahmin edilmesi amacıyla kullanılan Topluluk Öğrenmeleri (Ensemble Learning) modeli, test aşamasında elde edilen performans metriklerine göre başarılı bir sonuç ortaya koymuştur. Modelin R^2 (Test) değeri 0,8870 olarak hesaplanmış olup, bağımsız değişkenlerin bağımlı değişkendeki varyansın %88,7'sini açıkladığı görülmektedir. Ayrıca, RMSE (Test) değeri 0,0615 ile oldukça düşük bir hata oranına işaret etmektedir. Bu bulgular, EL modelinin tahmin performansı açısından güçlü bir genelleme kapasitesine sahip olduğunu göstermektedir. Geliştirilen Topluluk Öğrenmeleri modelinin performans ölçütleri Tablo 11'de verilmiştir.

Tablo 11: Topluluk Öğrenmeleri Modelinin Performans Ölçütleri

Aşamalar	Performans Ölçütleri			
	RMSE	MSE	R2	MAE
Eğitim Aşaması	0,1876	0,0352	0,4302	0,1436
Test Aşaması	0,0615	0,0038	0,8870	0,0480

Topluluk öğrenmeleri yöntemleri, birden fazla alt modelin çıktısını birleştirerek tek bir tahmin sonucuna ulaşmayı amaçlayan güçlü bir makine öğrenmesi yaklaşımıdır. Literatürde Breiman (2001) tarafından da belirtildiği gibi, Ensemble yöntemlerinin temel avantajı, bireysel modellerin zayıf yönlerini dengeleyerek toplam varyansı azaltması ve böylelikle genelleme performansını artırmasıdır. Bu çalışmada elde edilen yüksek R^2 değeri ve düşük RMSE değeri, Ensemble modelinin bu avantajlarını etkili bir şekilde yansıttığını göstermektedir.

Ensemble öğrenme yöntemleri genellikle bagging, boosting ve stacking gibi teknikleri kullanarak farklı alt modellerin çıktısını birleştirmektedir. Bagging yöntemleri (örneğin Random Forest), veri setini alt parçalara bölerek her bir parça üzerinde bağımsız modeller oluşturmakta ve sonuçları ortalamaya almaktadır. Bu yöntem, modelin varyansını azaltarak genelleme kapasitesini iyileştirmektedir. Boosting yöntemleri (örneğin Gradient Boosting), hatalı tahminlere odaklanarak modelleri ardışık şekilde eğitmekte ve daha doğru tahminler elde etmeyi amaçlamaktadır (Friedman, 2001). Bu çalışmada kullanılan Ensemble yöntemi, test aşamasında tutarlı sonuçlar üreterek hatayı minimize etmiş ve tahmin performansını artırmıştır.

Bu bağlamda, Ensemble modelinin düşük hata oranı ve yüksek açıklayıcılık gücü, modelin karmaşık ve doğrusal olmayan ilişkileri doğru bir şekilde yakalayabildiğini ortaya koymaktadır. Özellikle küçük veri setlerinde Ensemble yöntemleri, aşırı öğrenme (overfitting) riskini azaltarak daha güvenilir tahmin sonuçları sunmaktadır. Literatürde Ensemble öğrenme

yöntemlerinin ekonomik tahminler, zaman serisi analizleri ve tarımsal veriler gibi alanlarda yaygın olarak kullanıldığı ve başarılı sonuçlar elde edildiği vurgulanmaktadır (Dietterich, 2000; Breiman, 2001). Bu çalışmanın sonuçları da söz konusu bulgularla tutarlı olup, Ensemble modelinin tarım kredilerinin tahmini için etkili bir yöntem olduğunu göstermektedir.

Sonuç olarak, Ensemble modeli, $R^2 = 0,8870$ ve $RMSE = 0,0615$ değerleriyle çalışmada öne çıkan modellerden biri olmuştur. Modelin düşük hata oranı ve yüksek açıklayıcılık gücü, Ensemble yönteminin varyansı azaltarak genelleme performansını artırma kapasitesini kanıtlamaktadır. Tarım kredileri gibi karmaşık ilişkilerin bulunduğu tahmin problemlerinde Ensemble modellerinin kullanılması, güvenilir ve tutarlı sonuçlar elde edilmesine önemli katkılar sağlayabilir.

3.5. YAPAY SİNİR AĞLARI (YSA) YÖNTEMİNİN BULGULARI

Tarım kredilerinin tahmininde kullanılan Yapay Sinir Ağı (YSA) modeli, performans ölçütleri üzerinden detaylı olarak analiz edilmiştir. Modelin performansı hem eğitim (training) hem de test aşamalarında R^2 (Determinasyon Katsayısı) ve $RMSE$ (Kök Ortalama Kare Hata) gibi göstergeler kullanılarak değerlendirilmiştir.

Çalışmada kullanılan Yapay Sinir Ağı (YSA) modeli, temel olarak bir ileri beslemeli (feedforward) yapıya sahiptir ve tek gizli katman (hidden layer) ile tasarlanmıştır. Giriş katmanında, modelde bağımsız değişkenler olarak kullanılan altı girdi birimi (nöron) bulunmaktadır. Gizli katmanda ise 10 nöron kullanılmış ve aktivasyon fonksiyonu olarak sigmoid fonksiyonu tercih edilmiştir. Çıkış katmanında ise bir nöron yer almakta olup, bağımlı değişken olan tarım kredilerinin miktarı tahmin edilmiştir. Modelin eğitimi için geri yayılım (backpropagation) algoritması uygulanmış ve öğrenme oranı 0,01 olarak belirlenmiştir. Ayrıca, ağırlıkların ve önyargıların (bias) başlangıç değerleri, rastgele dağıtılmış küçük değerler olacak şekilde atanmıştır. Eğitim sürecinde aşırı öğrenme riskini azaltmak amacıyla erken durdurma (early stopping) stratejisi uygulanmıştır. Eğitim sırasında, kayıp fonksiyonu olarak ortalama kare hata (MSE) minimize edilmiştir. Bu topoloji, küçük veri setleriyle yapılan çalışmalarda yaygın olarak kullanılan basit ancak etkili bir yapı sunmakta olup, verinin sınırlı doğası göz önünde bulundurularak tasarlanmıştır.

Elde edilen bulgulara göre, YSA modeli eğitim aşamasında düşük bir R^2 değeri (0,1669) sergilemiştir. Bu durum, modelin eğitim verisindeki varyansın yalnızca %16,7'sini açıklayabildiğini göstermektedir. Ayrıca, $RMSE$ (Training) değeri 0,2268 olarak hesaplanmıştır. Eğitim aşamasında gözlenen bu düşük performans, YSA'nın karmaşık ilişkileri öğrenme kapasitesinin sınırlı kaldığına işaret etmektedir. Bu durum literatürde, küçük veri

setlerinde YSA modellerinin yüksek parametre sayısı nedeniyle aşırı öğrenme (overfitting) eğiliminde olmasına bağlanmaktadır (Hornik vd., 1989; Goodfellow vd., 2016).

Test aşamasında ise YSA modeli, eğitim performansına kıyasla daha iyi bir sonuç vermiş; ancak performans hâlâ sınırlı kalmıştır. R^2 (Test) değeri 0,6696 olarak hesaplanırken, RMSE (Test) değeri 0,1051 olarak elde edilmiştir. Bu sonuçlar, modelin test verisi üzerinde bağımlı değişkendeki varyansın yalnızca %66,9'unu açıklayabildiğini göstermektedir. Geliştirilen YSA modelinin performans ölçütleri Tablo 12'de verilmiştir.

Tablo 12: YSA Modeli Performans Ölçütleri

Aşamalar	Performans Ölçütleri			
	RMSE	MSE	R^2	MAE
Eğitim Aşaması	0,2268	0,0514	0,1669	0,1765
Test Aşaması	0,1051	0,0110	0,6697	0,0766

Ayrıca test aşamasında hesaplanan RMSE değerinin yüksek olması, YSA'nın tahmin hatasının belirgin olduğunu ortaya koymaktadır. Literatürde belirtildiği gibi, YSA modelleri büyük veri setlerinde başarılı sonuçlar verirken, küçük veri setlerinde genellikle öğrenme sürecinde sınırlılıklar yaşamaktadır. Hornik vd. (1989) tarafından ifade edildiği üzere, YSA'nın doğrusal olmayan ilişkileri öğrenme kapasitesi oldukça yüksektir; ancak bu başarı, veri seti büyüklüğü ve parametre optimizasyonu gibi faktörlere doğrudan bağlıdır. Özellikle küçük veri setlerinde YSA, model karmaşıklığı nedeniyle aşırı öğrenme eğilimindedir ve bu durum modelin genelleme kapasitesini azaltmaktadır. Goodfellow vd. (2016) da YSA modellerinin küçük veri setlerinde eğitilirken genellikle yüksek varyanslı tahminler ürettiğini ve bu nedenle performanslarının sınırlı kaldığını vurgulamaktadır.

Elde edilen bulgular; YSA modelinin küçük veri setlerinde karmaşık ilişkileri öğrenmekte zorlandığını göstermektedir. Eğitim ve test performansları arasındaki fark, modelin veriye tam uyum sağlayamadığını ve genelleme yapma kapasitesinin sınırlı olduğunu ortaya koymaktadır.

Sonuç olarak, YSA modeli test aşamasında $R^2 = 0,6696$ ve $RMSE = 0,1051$ değerleri ile orta düzeyde bir performans göstermiştir. Küçük veri setleri ile çalışırken YSA'nın başarısını artırmak için daha fazla veri sağlanması, parametre optimizasyonu yapılması ve aşırı öğrenme riskini azaltmak amacıyla regularization tekniklerinin kullanılması gerekmektedir. Bu bulgular, küçük veri setlerinde GPR gibi esnek ve parametrik olmayan yöntemlerin daha etkili olabileceğini desteklemektedir.

3.6. ÇOKLU DOĞRUSAL REGRESYON (MLR) YÖNTEMİNİN BULGULARI

Tarım kredilerinin tahmini için uygulanan MLR modelinin hem eğitim hem de test veri setleri üzerindeki performansı kapsamlı bir şekilde değerlendirilmiştir. Eğitim setindeki R^2 değeri 0.8528 ve test setindeki R^2 değeri 0.9078 olarak hesaplanmış, bu da modelin bağımlı değişkenin varyansının büyük bir kısmını açıklayabildiğini ortaya koymuştur. Ayrıca, eğitim ve test setlerinde elde edilen düşük hata değerleri (MSE, RMSE, MAE), modelin tahmin gücünün yüksek olduğunu ve hataların küçük bir aralıkta yoğunlaştığını göstermektedir. Artıkların dağılımına ilişkin analizde, hataların simetrik olduğu ve medyana yakın bir dağılım sergilediği gözlemlenmiştir. Bu bulgu, modelin ciddi bir sistematik sapma (bias) içermediğini ve matematiksel olarak uygun bir yapı oluşturduğunu desteklemektedir (Montgomery vd., 2021).

Bununla birlikte, bağımsız değişkenlerin p-değerleri incelendiğinde, hiçbirinin istatistiksel olarak anlamlı olmadığı ($p > 0.05$) görülmüştür. Bu durum, bağımsız değişkenlerin bağımlı değişken üzerindeki etkilerinin zayıf olduğunu veya modelde çoklu bağlantılılık probleminin bulunduğunu işaret etmektedir. Özellikle Yıllık tatlı su çekimi (tarım) ($p = 0.945$) ve Kentsel nüfus ($p = 0.815$) değişkenleri, model üzerindeki etkilerinin ihmal edilebilir düzeyde olduğunu göstermektedir. Serbestlik derecesinin ($df = 11$) düşük olması, modelin genelleme kapasitesini sınırlayan bir diğer önemli faktör olarak öne çıkmaktadır. Veri setinin sınırlı büyüklüğü, modelin bağımsız değişkenlerin etkilerini doğru bir şekilde tahmin edebilme kapasitesini önemli ölçüde kısıtlamaktadır (Kutner vd., 2004). Eğitim setindeki düzeltilmiş R^2 değeri (0.7725), bağımsız değişken sayısına göre açıklayıcılığın bir miktar azaldığını göstermekle birlikte, hala modelin güçlü bir performans sergilediğini ortaya koymaktadır. Ancak, test setindeki gözlem sayısının bağımsız değişken sayısından az olması nedeniyle düzeltilmiş R^2 değeri test aşaması için hesaplanamamıştır.

Sonuç olarak, analiz bulguları, modelin tahmin performansının yüksek olduğunu göstermesine rağmen, bağımsız değişkenlerin anlamlılık düzeylerinin düşük olması, modelin teorik çıkarımlar yapabilme kabiliyetini sınırlamaktadır. Bu durum, modelin pratik uygulamalarda başarılı olabileceğini gösterse de akademik ve teorik bağlamda daha fazla doğrulama ve iyileştirme çalışmasının yapılması gerektiğini işaret etmektedir. Geliştirilen MLR modelinin performans ölçütleri Tablo 13'te verilmiştir.

Tablo 13: MLR Modelinin Performans Ölçütleri

Aşamalar	Performans Ölçütleri			
	RMSE	MSE	R2	MAE
Eğitim Aşaması	0.0895	0.0080	0.8528	0.0746
Test Aşaması	0.0555	0.0030	0.9078	0.0436

3.7. GELİŞTİRİLEN MODELLERİN KARŞILAŞTIRILMASI

Bu tez çalışmasında, tarım kredilerinin tahmin edilmesi amacıyla Gauss Süreç Regresyonu (GPR), Yapay Sinir Ağı (YSA), Destek Vektör Regresyonu (SVR), Karar Ağacı (DT) ve Topluluk Öğrenme (Ensemble Learning) yöntemleri kullanılmış ve performansları çeşitli değerlendirme ölçütleri üzerinden analiz edilmiştir. Elde edilen bulgular, her bir modelin güçlü ve zayıf yönlerini ortaya koyarak, küçük veri setleri ile çalışmanın getirdiği kısıtlar altında hangi yöntemin daha etkili sonuçlar verdiğini göstermektedir. Modellerin performans karşılaştırması, RMSE (Kök Ortalama Kare Hata) ve R^2 (Determinasyon Katsayısı) gibi yaygın ölçütler kullanılarak yapılmıştır. Geliştirilen tüm modellerin performans ölçütleri Tablo 14'te verilmiştir.

Tablo 14: Karşılaştırmalı Performans Ölçütleri

Model	Eğitim Aşaması				Test Aşaması			
	RMSE	MSE	R^2	MAE	MAE	MSE	RMSE	R^2
GPR	0,1846	0,0341	0,4482	0,1197	0,0446	0,0030	0,0545	0,9110
YSA	0,2268	0,0514	0,1669	0,1765	0,0766	0,0110	0,1051	0,6697
SVR	0,1315	0,0173	0,7200	0,0848	0,0479	0,0062	0,0787	0,8150
Karar Ağacı	0,1876	0,0352	0,4302	0,1436	0,0791	0,0089	0,0942	0,7346
Topluluk Öğrenmeleri	0,1492	0,0223	0,6396	0,0946	0,0480	0,0038	0,0615	0,8870
MLR	0.0895	0.0080	0.8528	0.0746	0.0436	0.0030	0.0555	0.9078

GPR modeli, test aşamasında $R^2 = 0,9110$ ve $RMSE = 0,0545$ değerleriyle en yüksek performansı sergilemiştir. Bu bulgular, GPR'nin doğrusal olmayan ve karmaşık ilişkileri başarılı bir şekilde modelleyebildiğini göstermektedir. Literatürde belirtildiği üzere, GPR, parametrik olmayan yapısı sayesinde küçük veri setlerinde dahi yüksek genelleme kapasitesi sunmakta ve kernel fonksiyonları aracılığıyla doğrusal olmayan ilişkileri esnek bir şekilde öğrenebilmektedir (Rasmussen & Williams, 2006). Bu çalışmanın bulguları, GPR'nin küçük veri setlerinde diğer modellere kıyasla daha başarılı sonuçlar verdiğini önceki çalışmalarla tutarlıdır. Modelin test performansındaki başarısı, özellikle verideki doğrusal olmayan yapıyı doğru bir şekilde modellemesinden kaynaklanmaktadır.

Buna karşılık Yapay Sinir Ağı (YSA) modeli, eğitim aşamasında $R^2 = 0,1669$ ve $RMSE = 0,2268$ gibi düşük bir performans sergilemiş; test aşamasında ise $R^2 = 0,6696$ ve $RMSE =$

0,1051 değerleri ile orta düzeyde bir performans göstermiştir. Bu durum, YSA'nın küçük veri setlerinde karmaşık ilişkileri tam olarak öğrenemediğini ve genelleme kapasitesinin sınırlı olduğunu ortaya koymaktadır. Literatürde, küçük veri setlerinde YSA'nın yüksek parametre sayısı ve karmaşıklığı nedeniyle aşırı öğrenme eğiliminde olduğu ve bu durumun model performansını olumsuz etkilediği belirtilmektedir (Hornik vd., 1989; Goodfellow vd., 2016). Bu nedenle YSA'nın başarısının artırılabilmesi için daha büyük veri setlerinin kullanılması ve parametre optimizasyonunun dikkatli bir şekilde yapılması gerekmektedir.

Destek Vektör Regresyonu (SVR) modeli ise test aşamasında $R^2 = 0,8150$ ve $RMSE = 0,0786$ değerleri ile başarılı bir performans sergilemiştir. Gaussian Kernel kullanımı, SVR'nin doğrusal olmayan ilişkileri etkili bir şekilde öğrenmesini sağlamış ve Box Constraint ile Epsilon parametrelerinin optimize edilmesi sayesinde modelin genelleme kapasitesi artırılmıştır. Literatürde SVR'nin küçük ve orta büyüklükteki veri setlerinde doğrusal olmayan yapıları doğru bir şekilde öğrenebildiği ve yüksek doğruluk sağladığı ifade edilmektedir (Smola & Schölkopf, 2004). Ancak test aşamasında elde edilen RMSE değerinin GPR'ye kıyasla daha yüksek olması, SVR'nin doğrusal olmayan yapıları öğrenme kapasitesinin bazı sınırlılıklarını ortaya koymaktadır.


Karar Ağacı modeli, test aşamasında $R^2 = 0,7346$ ve $RMSE = 0,0942$ değerleri ile orta düzeyde bir performans göstermiştir. Modelin doğrusal olmayan yapıları öğrenebilme kapasitesi, verideki ilişkilerin açıklanmasında etkili olmuştur. Ancak literatürde belirtildiği gibi, Karar Ağaçları küçük veri setlerinde aşırı öğrenme riski taşımakta ve bu durum modelin genelleme performansını sınırlamaktadır (Breiman vd., 1984). Bu çalışmada da modelin hata oranlarının diğer modellere kıyasla daha yüksek olması, aşırı dallanma ve küçük veri setindeki kısıtlı gözlem sayısı ile ilişkilendirilebilir.

Topluluk Öğrenmeleri (Ensemble Learning) modeli ise test aşamasında $R^2 = 0,8870$ ve $RMSE = 0,0615$ değerleri ile dikkat çekici bir performans göstermiştir. Topluluk yöntemleri, birden fazla alt modelin çıktısını birleştirerek varyansı azaltmakta ve genelleme kapasitesini artırmaktadır. Literatürde de belirtildiği gibi, Topluluk yöntemlerinin bireysel modellerin zayıf yönlerini dengeleyerek daha tutarlı ve güvenilir sonuçlar verdiği ifade edilmektedir (Breiman, 2001; Friedman, 2001). Bu çalışmada elde edilen sonuçlar, Topluluk modelinin düşük hata oranı ve yüksek açıklayıcılık gücü ile güçlü bir alternatif olduğunu göstermektedir.


MLR yöntemi, eğitim aşamasında nispeten güçlü bir düzeltilmiş R^2 değeri (0.7725) sergilese de, bağımsız değişkenlerin istatistiksel olarak anlamlı olmaması ($p > 0.05$) ve serbestlik derecesinin düşük olması ($df = 11$), modelin genelleme kapasitesini sınırlamaktadır. Test aşamasında doğrusal olmayan ilişkileri yeterince modelleyememesi ve (çoklu doğrusallık

problemi), MLR'nin GPR, SVR veya Topluluk Öğrenmeleri gibi daha esnek yöntemlere kıyasla yetersiz kalmasına neden olmuştur. Bu nedenle, MLR yöntemi, veri setinin karmaşık yapısını yeterince temsil edemediği için bu veri seti için uygun bir seçim değildir.

Geliştirilen tüm modellerin R^2 değerleri RMSE değerlerini karşılaştıran sütun grafiği Şekil 20'de verilmiştir.



(a)



(b)

Şekil 20: Geliştirilen Modellerin R^2 (a) Değerleri RMSE (b) Değerlerinin Karşılaştırılması

Şekil 20'de de açıkça görüldüğü gibi, tarım kredilerinin tahmini için uygulanan modeller arasında GPR modeli, en düşük hata oranı ($RMSE = 0,0545$) ve en yüksek açıklayıcılık gücü ($R^2 = 0,9110$) ile en başarılı model olarak öne çıkmıştır. Topluluk Öğrenmeleri modeli ise ikinci sırada yer alarak tutarlı ve güvenilir bir performans sergilemiştir. SVR modeli, test aşamasında yüksek doğruluk sağlamakla birlikte, hata oranı GPR'ye kıyasla daha yüksektir. Karar Ağacı ve YSA modelleri ise genelleme performansında sınırlı kalmış ve

diğer modellere göre daha yüksek hata oranlarına sahip olmuştur. Bu bulgular, küçük veri setlerinde parametrik olmayan ve esnek yapıya sahip olan GPR ve Topluluk Öğrenmeleri yöntemlerinin doğrusal olmayan ilişkileri modellemede daha başarılı sonuçlar verdiğini göstermektedir.



SONUÇ, TARTIŞMA VE ÖNERİLER

Sonuç

Bu tez çalışması, tarımsal kredilerin tahmini ve bu kredilerin etkin yönetimi için makine öğrenmesi ve istatistiksel modellerin karşılaştırılmasını amaçlayarak hem literatüre hem de tarım ekonomisi uygulamalarına önemli katkılar sunmuştur. Tarım sektörü, Türkiye ekonomisinin temel taşlarından biri olup, kırsal kalkınma, gıda güvenliği ve ekonomik sürdürülebilirlik gibi kritik alanlarda belirleyici bir rol oynamaktadır. Bu bağlamda, tarımsal finansman kaynaklarının doğru tahmin edilmesi ve etkin bir şekilde yönetilmesi, sektörel büyümeyi desteklerken, finansal risklerin minimize edilmesi açısından da hayati bir öneme sahiptir. Çalışmanın sonuçları, makine öğrenmesi yaklaşımlarının bu alanda sağladığı yüksek doğruluk ve adaptif kapasite ile geleneksel yöntemlere kıyasla daha üstün bir performans sergilediğini ortaya koymuştur.

Makine öğrenmesi modelleri, tarımsal kredilerin tahmininde geleneksel istatistiksel yöntemlerin sınırlarını aşarak daha hassas ve etkili sonuçlar ortaya koymuştur. Geleneksel yöntemlerden Çok Değişkenli Doğrusal Regresyon (MLR), doğrusal olmayan ilişkilerin yoğun olduğu tarım sektöründe yetersiz kalırken, Gauss Süreç Regresyonu (GPR) ve Destek Vektör Regresyonu (SVR) gibi modern makine öğrenmesi teknikleri, ekonomik ve çevresel değişkenlerin etkilerini daha doğru analiz etme kapasitesi sunmaktadır. Özellikle GPR, doğrusal olmayan karmaşık ilişkileri modelleme yeteneği ile öne çıkarken, Topluluk Öğrenme (Ensemble Learning) yaklaşımları ise modellerin birleştirilmesi yoluyla tahmin doğruluğunu ve genelleme kapasitesini önemli ölçüde artırmıştır. Bu sonuçlar, Breiman (2001) gibi literatürde makine öğrenmesi yöntemlerinin üstün performansını vurgulayan çalışmaları desteklemekte ve Liakos vd. (2018) tarafından tarımsal veri analizi için önerilen makine öğrenmesi yaklaşımlarının etkinliğini bir kez daha kanıtlamaktadır.

Araştırma, tarımsal kredi tahmininde etkili olan temel faktörlere de ışık tutmuştur. Özellikle tarım arazilerinin sulanabilirlik oranları ve etkin kullanımı, kredi talebinin şekillenmesinde önemli bir rol oynamıştır. Sulanan tarım alanlarının artışı, üretim kapasitesini artırarak tarımsal gelirleri desteklemiş ve bu durum kredi talebine pozitif bir şekilde yansımıştır. Bunun yanında, tarımsal faaliyetlerin Gayri Safi Yurtiçi Hasıla (GSYİH) içindeki payı, sektördeki finansman ihtiyacını belirleyen önemli bir değişken olarak öne çıkmıştır. Kentsel nüfusun artışı ise tarımsal ürünlere olan talebi dolaylı yoldan artırarak kredi ihtiyacını etkilemiştir. Bu bulgular, ekonomik, sosyal ve çevresel faktörlerin tarımsal finansman üzerindeki etkilerini somut bir şekilde ortaya koymaktadır.

Sonuç olarak, bu çalışma, makine öğrenmesi tekniklerinin tarımsal kredi tahmininde istatistiksel yöntemlere kıyasla daha etkili olduğunu göstermiş ve bu yöntemlerin tarım ekonomisinde uygulama potansiyelini ortaya koymuştur. Türkiye gibi tarıma dayalı ekonomilerde, makine öğrenmesi modelleri, kırsal kalkınma ve tarımsal üretim politikalarının geliştirilmesi, finansal kaynakların daha verimli yönetilmesi ve risk analizlerinin etkin bir şekilde yapılması için güçlü bir araç sunmaktadır. Ayrıca, bu modellerin dinamik yapısı, gelecekte tarımsal kredilerin yönetimi ve planlamasında kamu politikalarına doğrudan katkı sağlayabilecek bir perspektif sunmaktadır. Çalışma, sadece akademik literatüre değil, aynı zamanda tarım ekonomisinin modernizasyonu ve finansal yönetim stratejilerinin geliştirilmesine yönelik önemli bir rehber niteliği taşımaktadır. Gelecekte daha geniş veri setleri ve hibrit yaklaşımlarla yapılacak çalışmalar, bu alandaki bilgi birikimini daha da ileri taşıyabilecektir.

Tartışma

Bu çalışma, tarımsal kredi tahmini alanında makine öğrenmesi modellerinin uygulanabilirliği ve performansına odaklanarak literatüre hem teorik hem de uygulamalı katkılar sağlamaktadır. Literatürde, Breiman (2001) gibi makine öğrenmesi yöntemlerinin karmaşık ilişkileri modelleme kapasitesini vurgulayan çalışmalarla uyumlu olarak, bu çalışmanın bulguları da GPR, SVR ve Topluluk Öğrenme yöntemlerinin doğruluğunu ve genelleme kapasitesini açıkça ortaya koymaktadır. Özellikle GPR modelinin doğrusal olmayan ilişkileri modelleme başarısı, Liakos vd. (2018) tarımsal veri analizlerinde makine öğrenmesi tekniklerinin önemi üzerine yaptığı vurgularla örtüşmektedir. Geleneksel istatistiksel yöntemlerin doğrusal olmayan karmaşık yapıları modellemedeki yetersizlikleri bu çalışma kapsamında açıkça görülmüş ve Doll ve Orazem (2005) gibi istatistiksel yöntemlerin tarım sektöründeki sınırlılıklarına dikkat çeken literatürle paralellik göstermiştir. Bu bağlamda, Türkiye'nin tarım ekonomisi dinamiklerinin, özellikle coğrafi ve sosyo-ekonomik farklılıkların, modellerin doğruluk performansı üzerindeki etkisi dikkat çekici bir tartışma konusudur.

Elde edilen bulgular, tarımsal kredilerin tahmini üzerine yapılan önceki çalışmalarla büyük ölçüde uyumlu olmakla birlikte, kullanılan makine öğrenmesi yöntemlerinin farklı veri seti özelliklerine nasıl uyarlanabileceğine dair yeni perspektifler sunmaktadır. Örneğin, SVR ve GPR gibi yöntemlerin karmaşık ve doğrusal olmayan ilişkileri öğrenme kapasitesi, Breiman (2001) ve Bishop (2006) gibi literatürde yer alan çalışmalar tarafından desteklenmektedir. Ancak, Yapay Sinir Ağları (YSA) modeli, küçük veri setlerinde genelleme kapasitesinde sınırlılıklar göstermiş ve bu durum, Goodfellow vd. (2016) küçük veri setlerinde YSA'nın performansına dair bulgularıyla örtüşmüştür. Ayrıca, bu çalışmada kullanılan veri setinin

genişliği ve değişkenlerin tarımsal kredi tahminine olan etkisi, literatürde sıkça vurgulanan veri kalitesi ve değişken seçim kriterlerinin önemini bir kez daha doğrulamaktadır.

Makine öğrenmesi modellerinin seçim kriterleri, bu çalışmanın metodolojisinin temel unsurlarından biri olmuştur. Modellerin seçimi sırasında doğrusal olmayan ilişkileri öğrenme kapasitesi, performans metriği optimizasyonu ve veri setine uygunluk gibi faktörler dikkate alınmıştır. GPR ve SVR modellerinin tercih edilmesi, bu kriterlerin doğrudan bir sonucudur ve bu modellerin tahmin doğruluğunda sağladığı başarı, çalışmanın bulgularını güçlendirmiştir. Ayrıca, veri setindeki değişkenlerin genişliği ve derinliği, modellerin genelleme kapasitesini önemli ölçüde artırmıştır. Bununla birlikte, daha geniş bir coğrafi kapsama sahip veri setleri ve farklı veri kaynaklarının entegrasyonu, sonuçların genellenebilirliğini daha da iyileştirebilecektir. Alternatif makine öğrenmesi modelleri veya hibrit yaklaşımlar uygulandığında sonuçların değişme potansiyeli ise tartışılması gereken bir diğer önemli hususlardan biridir.

Sonuçların uygulanabilirliği açısından, bu çalışma, tarımsal kredilerin yönetimi ve politikalarının geliştirilmesine yönelik çeşitli öneriler sunmaktadır. Bulgular, finansal kurumlar ve kamu politikası yapıcılar için daha verimli kredi yönetim stratejilerinin geliştirilmesine katkıda bulunabilecektir. Ayrıca, makine öğrenmesi modellerinin tarım sektörü için uygulanması, kırsal kalkınma ve gıda güvenliği gibi hedeflere ulaşılmasına da katkı sağlayabilecektir. Bu modellerin tahmin doğruluğu ve genelleme kapasitesi, özellikle finansal risklerin azaltılmasında ve kredi politikalarının optimize edilmesinde etkili bir araç olarak değerlendirilebilecektir.

Çalışmanın sınırlılıkları arasında veri setinin boyutunun küçük olması ve coğrafi kapsamının sınırlı kalması yer almaktadır. Bu durum, modellerin genelleme kapasitesini kısmen sınırlandırmış ve sonuçların farklı ekonomik bağlamlara uygulanabilirliğini kısıtlamıştır. Ayrıca, veri setinde yer alan eksiklikler ve doğruluk sorunları, model performansı üzerinde sınırlı da olsa etkiler yaratmış olabilmektedir. Gelecekte, daha geniş ve farklı veri setleriyle yapılacak çalışmalar, tarımsal kredi tahmini alanında daha kapsamlı ve genellenebilir sonuçlar sunabilecektir. Hibrit yaklaşımlar, örneğin makine öğrenmesi ve geleneksel yöntemlerin birleşimi, tahmin performansını daha da artırabilecektir. Ayrıca, tarımsal kredi tahmininde diğer bağımsız değişkenlerin etkisinin incelenmesi, bu alanda literatüre yeni katkılar sağlayabilir.

Sonuç olarak, bu çalışma, hem mevcut bulgularıyla literatüre önemli bir katkı sunmakta hem de gelecekteki araştırmalara rehberlik edecek potansiyel yollar göstermektedir. Makine

öğrenmesi yöntemlerinin tarım kredileri gibi ekonomik problemlerde optimize edilmesi, bu alanda daha ileri düzeyde araştırmalar yapılmasının önünü açacaktır.

Öneriler

Tarım sektörü, Türkiye ekonomisinde kritik bir öneme sahip olup, kırsal kalkınma, gıda güvenliği ve ekonomik sürdürülebilirlik hedefleri açısından stratejik bir role sahiptir. Bu bağlamda, tarımsal kredilerin doğru tahmini ve etkin yönetimi, kaynakların verimli bir şekilde dağıtılmasına olanak tanımakta ve tarımsal üretimi desteklemektedir. Ancak, tarım sektöründeki ekonomik, sosyal ve çevresel dinamiklerin karmaşıklığı, geleneksel yöntemlerin tahmin kapasitesini sınırlamaktadır. Makine öğrenmesi yöntemleri, bu sınırlılıkların üstesinden gelmek için alternatif bir çözüm sunmakta ve karmaşık veri yapılarında yüksek doğruluklu tahminler sağlamaktadır. Bu çalışma, tarımsal kredilerin tahminine yönelik çeşitli makine öğrenmesi modellerini uygulayarak, bu yöntemlerin geleneksel yaklaşımlara kıyasla üstünlüklerini değerlendirmiş ve gelecekteki araştırmalar için yol gösterici bir çerçeve sunmayı amaçlamıştır.

Bu çalışmada kullanılan veri seti, 23 yıllık bir dönemi kapsayarak tarım kredilerinin tahmini için önemli bir temel oluşturmuştur. Ancak, daha geniş bir coğrafi kapsam ve daha uzun bir zaman dilimini içeren veri setlerinin kullanılması, modelin genelleme kapasitesinin artırılmasını sağlayacaktır. Özellikle, bölgesel farklılıkların daha ayrıntılı bir şekilde analiz edilmesi ve tarımsal kredi talebindeki uzun vadeli eğilimlerin ortaya konması, çalışmanın sonuçlarını daha kapsamlı hale getirebilmektedir.

Türkiye'nin farklı bölgelerinde tarım sektörü, ekonomik ve çevresel koşullara bağlı olarak değişiklik göstermektedir. Modellerin performansı, bu farklılıkların tarımsal kredi kullanımına etkilerini değerlendirme açısından önemli bir fırsat sunmaktadır. Kentsel ve kırsal bölgelerdeki kredi kullanım dinamiklerinin detaylı bir şekilde analiz edilmesi, bölgesel kalkınma politikalarının geliştirilmesine katkı sağlayabilecektir. Bunun yanı sıra, hava durumu, tarımsal ürün fiyatlarındaki dalgalanmalar ve çiftçi gelirleri gibi ek değişkenlerin modele dahil edilmesi, tahminlerin doğruluğunu artırabilecektir ve tarım sektörü ile finansal kaynaklar arasındaki ilişkiyi daha iyi açıklayabilecektir.

Makine öğrenmesi modellerinin yanı sıra hibrit yaklaşımlar, bu çalışmanın kapsamını genişletebilecek önemli bir alternatiftir. Gauss Süreç Regresyonu (GPR) ve Topluluk Öğrenme (Ensemble Learning) gibi güçlü yöntemlerin kombinasyonu, veri setindeki doğrusal olmayan ilişkileri daha etkili bir şekilde modelleyebilecektir. Bu tür hibrit yaklaşımlar, farklı modellerin avantajlarını birleştirerek daha hassas ve güvenilir tahminler sağlayabilecektir.

Bu çalışmanın bulguları, makine öğrenmesi modellerinin tarımsal kredi tahmininde geleneksel yöntemlerin ötesinde önemli avantajlar sunduğunu ortaya koymaktadır. Geleneksel yaklaşımların sınırlı çözümüleme kapasitesi, makine öğrenmesi yöntemlerinin adaptif ve dinamik yapısıyla aşılmıştır. Özellikle Türkiye gibi tarıma dayalı ekonomilerin bulunduğu coğrafyalarda, bu modellerin hem kırsal kalkınmayı destekleyen politikaların oluşturulmasında hem de finansal kaynakların daha etkili bir şekilde yönetilmesinde kritik bir rol oynayabileceği görülmüştür. Gelecekteki çalışmalarda, daha geniş veri setleri, hibrit yaklaşımlar ve farklı bağımsız değişkenlerin entegrasyonu, tarımsal kredi tahmin modellerinin geliştirilmesi için önemli bir potansiyel taşımaktadır.



KAYNAKÇA

- Acar, M. (2003). Fiyat desteğinden doğrudan desteğe: Dünyada tarımsal destekleme politikalarında yeni yönelimler. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 3(2), 101-116.
- Acar, M. (2006). *DTÖ ve AB ışığında Türk tarımının geleceği*. Ankara: Orion Yayınevi.
- Acuna, E., & Rodriguez, C. (2004). The treatment of missing values and its effect on classifier accuracy. In D. Banks, L. House, F. R. McMorris, P. Arabie, & W. Gaul (Eds.), *Classification, clustering, and data mining applications* (pp. 639–647). Springer. https://doi.org/10.1007/978-3-642-17103-1_60
- Akdeniz, Z. (2019). *Türkiye’de tarım sektörü ve 2000’li yıllarda tarımda izlenen politikalar* (Yayımlanmamış yüksek lisans tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul, Türkiye.
- Allison, P. D. (2001). *Missing data*. Sage Publications. <https://doi.org/10.4135/9781412985079>
- Aral, S., & Sakarya, E. (1996). Avrupa Birliğine giriş sürecinde Türkiye’de hayvancılık politikaları ve alınması gerekli önlemler. *Avho-Ankara Bölgesi Veteriner Hekimler Odası Dergisi*.
- Aras, G. (1995). *Ticari bankalarda kredi portföyünün yönetimi*. Marmara Üniversitesi (Turkey).
- Ardeni, P. G., & Freebairn, J. (2002). The Macroeconomics of agriculture. *Handbook of Agricultural Economics*, 2, 1455-1485.
- Avşar, E. (2009). *Tek-sınıf destek vektör makineleri kullanılarak epileptik EEG işaretlerinin sınıflandırılması* (Yüksek lisans tezi). Yükseköğretim Kurulu Ulusal Tez Merkezi’nden edinilmiştir. (Tez No. 251692)
- Aydın, S., & Özkul, A. E. (2015). Veri madenciliği ve Anadolu üniversitesi açık öğretim sisteminde bir uygulama. *Eğitim ve Öğretim Araştırmaları Dergisi*, 4(3), 36-44.
- Babuşcu, Ş., & Hazar, A. (2017). *Genel bankacılık bilgileri*. Ankara: Bankacılık Akademisi Yayınları.
- Bahşi, N., & Çetin, E. (2020). Determining of agricultural credit impact on agricultural production value in Turkey. *Ciência Rural*, 50, e20200003.
- Batista, G. E. A. P. A., & Monard, M. C. (2003). An analysis of four missing data treatment methods for supervised learning. *Applied Artificial Intelligence*, 17(5-6), 519–533. Erişim Adresi: <https://doi.org/10.1080/713827181>
- Bilgin, M. (2018). *Makine öğrenmesi: Teorisi ve algoritmaları*. İstanbul: Papatya Yayıncılık.
- Bingöl, Ş., & Meçik, O. (2021). Yeni kapitalizm ve Türkiye’de tarım sektörünün dönüşümü. *Afyon Kocatepe Üniversitesi Sosyal Bilimler Dergisi*, 23(2), 586-605.
- Binswanger, H. P., & Khandker, S. R. (1995). The impact of formal finance on the rural economy of India. *The Journal of Development Studies*, 32(2), 234–262. <https://doi.org/10.1080/00220389508422413>
- Bishop, C. M. (2006). *Pattern recognition and machine learning*. New York, NY: Springer.
- Boz, İ. (2004). Tarım sektörünün iktisadi kalkınmadaki rolü. In S. Taban & M. Kar (Eds.), *Kalkınma ekonomisi: Seçme konular* (ss. 137–158). Bursa: Ekin Kitabevi Yayınları.
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>.

- Breiman, L., Friedman, J., Olshen, R. A., & Stone, C. J. (1984). Classification and Regression Trees. Wadsworth & Brooks.
- Budak, H., & Erpolat, S. (2012). Kredi riski tahmininde yapay sinir ağıları ve lojistik regresyon analizi karşılaştırılması. *AJIT-e: Academic Journal of Information Technology*, 3(9), 23-30.
- Bülbül, M. (2006). *Tarımsal İşletmelerin Finansmanı*. (Yayın No:1549). Ankara: Ankara Üniversitesi Basımevi.
- Bülbül, M., Çadırcı, E., & Güneş, E. (1995). Tarımsal Krediler ve Uygulamaları. *Türkiye Ziraat Mühendisliği IV. Teknik Kongresi*, 9-13.
- Cole, R. H., & Mishler, L. (1998). Consumer and business credit management. (No Title).
- CSBB (T.C. Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı). (2023). 2024 yılı merkezi yönetim bütçe teklifi. <https://www.sbb.gov.tr>.
- Çak, M., & Yavuz, E. (2023). Türkiye’de tarım sektörüne yönelik vergisel kolaylıkların sosyo-ekonomik açıdan incelenmesi ve gıda güvencesi bağlamında değerlendirilmesi. *Maliye Çalışmaları Dergisi*, (69), 49-69.
- Çelik, N. (2000). *Tarımda girdi kullanımı ve verimliliğe etkileri*. DPT.
- Çelik, N. (2012). *Dünyada ve Türkiye’de kooperatiflerin ekonomik ve sosyal kalkınmadaki rolü* (Yüksek lisans tezi). Yükseköğretim Kurulu Ulusal Tez Merkezi’nden edinilmiştir. (Tez No. 331215)
- Çetin, B. (2020). Tarımsal finansman, geliştirilmiş. (3. Baskı).
- Çomaktekin, M. F. (2009). *Tarımsal destekleme politikaları ve Türkiye’de uygulamalar: 1990 ve sonrası dönem* (Yüksek lisans tezi). Yükseköğretim Kurulu Ulusal Tez Merkezi’nden edinilmiştir. (Tez No. 261899)
- Demir, N. (2012). AB ve Türkiye’de hayvancılık politikalarındaki son gelişmelerin uyum süreci açısından karşılaştırılması. *Alinteri Journal of Agriculture Science*, 23(2), 58-63.
- Demirbulut, Y., Aktaş, M., Kalıpsız, O., & Bayracı, S. (2017). İstatistiksel ve makine öğrenimi yöntemleriyle kredi skorlama.
- Demirtaş, N., & Tosun, D. (2005). Türkiye’de tarımın sanayi ile entegrasyonu, ortaya çıkan sorunlar ve çözüm önerileri. *Adnan Menderes Üniversitesi Ziraat Fakültesi Dergisi*, 2(2), 27-34.
- Deran, A. (2005). *Meyve bahçelerinde maliyetlerin muhasebe kuramı çerçevesinde hesaplanması ve uygulamaları* (Yayımlanmamış doktora tezi). Gazi Üniversitesi Sosyal Bilimler Enstitüsü, Ankara, Türkiye.
- Dietterich, T. G. (2000). Ensemble methods in machine learning. In J. Kittler & F. Roli (Eds.), *Multiple classifier systems* (Lecture Notes in Computer Science, Vol. 1857, pp. 1–15). Berlin, Heidelberg: Springer. https://doi.org/10.1007/3-540-45014-9_1
- Dinler, Z. (2000). *Tarım ekonomisi*. Bursa: Ekin Kitabevi Yayınları.
- Direk, M. (2010). *Tarım tarihi ve deontoloji*. Konya: Eğitim Akademi Yayınları.
- Dogan, H., & Atik, K. (2004). Providing persistence in comfort conditions by the application of artificial neural networks to air-conditioning systems. *Technology*, 7(2).
- Doğan, A. (2009). Ekonomik Gelişme Sürecine Tarımın Katkısı: Türkiye Örneği. *Sosyal Ekonomik Araştırmalar Dergisi*, 9(17), 365-392.
- Doğan, S., & Türe, H. (2022). Makine öğrenmesi teknikleri ile ülke riski tahmini. *Fiscaoeconomia*, 6(3), 1126-1151.

- Doğan, Z., Arslan, S., & Berkman, A. (2015). Türkiye’de tarım sektörünün iktisadi gelişimi ve sorunları: Tarihsel bir bakış. *Niğde Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 8(1), 29-41.
- Doll, J. P., & Orazem, F. (2005). *Teorik ve uygulamalı üretim ekonomisi* (Ş. Akdemir, Ed.; T. Alemdar, Trans.). Ankara: Seçkin Yayıncılık.
- Drucker, H., Burges, C. J. C., Kaufman, L., Smola, A., & Vapnik, V. (1997). Support vector regression machines. In M. C. Mozer, M. I. Jordan, & T. Petsche (Eds.), *Advances in neural information processing systems* (Vol. 9, pp. 155–161). Cambridge, MA: MIT Press.
- Duman, S., & Türkmen, S. Y. (2023). Bankacılık sektöründe kredi risk yönetimi ve bir tahmin modeli örneği. *Finansal Araştırmalar ve Çalışmalar Dergisi*, 15(28), 1-14.
- Durak, Ş. (2000). *Tekstil sektörü kredi analizi* (Yayımlanmamış yüksek lisans tezi). İstanbul Teknik Üniversitesi, İstanbul, Türkiye.
- Ege, H. (2011). Tarım sektörünün ekonomideki yeri ve önemi. *Tarımsal Ekonomi ve Politika Geliştirme Enstitüsü Tepgebakış*, 7, 1303-8346.
- Ellis, F., & Biggs, S. (2001). Evolving themes in rural development 1950s-2000s. *Development policy review*, 19(4), 437-448.
- Erbay, R. (2013). Ekonomik kalkınmada tarımın rolü: Türkiye üzerine bir değerlendirme. *Balkan Sosyal Bilimler Dergisi*, 2(4).
- Erdaş, H. (2012). *Türkiye’de tarımın finansmanında banka kredilerinin rolü: Edirne bölgesi örneği* (Doktora tezi). Yükseköğretim Kurulu Ulusal Tez Merkezi’nden edinilmiştir. (Tez No. 305276.)
- Erdem, E. (2010). *Para, banka ve finansal sistem*. Ankara: Detay Yayıncılık.
- Erdem, E., & Yücel, A. G. (2015). Türk tarım sektöründe tohumluk kullanımı ve verimlilik ilişkisi üzerine bir uygulama. *Bilgi Ekonomisi ve Yönetimi Dergisi*, 10(2).
- Ersoy, M., & şerafettin Özsoy, M. (2017). Tarım finansmanının kalkınmadaki rolü ve önemi: bir model önerisi. *Öneri Dergisi*, 12(47), 1-14.
- Ertuğrul, İ., & Özçil, A. (2017). Bireysel tüketici ihtiyaç kredisi talep tahminlerinin vektör oto regresyon ve yapay sinir ağı modelleri ile karşılaştırmalı analizi. *Finansal Araştırmalar ve Çalışmalar Dergisi*, 9(16), 19-38.
- FAOSTAT. (2023), Tarım Kredileri Verileri, <https://www.fao.org/faostat/en/#home>.
- Foltz, J. D. (1998). Credit Market Constraints and Profitability in Tunisian Agriculture.
- Food and Agriculture Organization of the United Nations. (2017). *The future of food and agriculture: Trends and challenges*. Fao.
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189–1232. <https://doi.org/10.1214/aos/1013203451>.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Gour, R. (2019). Unique Real-Life Applications of SVM. Retrieved October 24, 2020, from <https://medium.com/@rinu.gour123/8-unique-real-life-applications-ofsvm-8a96ca43313>.
- Gunes, E., & Movassaghi, H. (2017). Agricultural Credit Market and Farmers ‘Response: A Case Study of Turkey. *Turkish Journal of Agriculture-Food Science and Technology*, 5(1), 84-92.

- Guyon, I., & Elissee, A. (2003). An introduction to variable and feature selection. *Journal of Machine Learning Research*, 3(Mar), 1157-1182.
- Güteryüz, D. (2020). Evaluation of waste management using clustering algorithm in megacity Istanbul. *Environmental Research and Technology*, 3(3), 102-112.
- Günaydın, G. (2006). Türkiye tarım sektörü. *Tarım ve Mühendislik Dergisi*, 76-77, 12-27.
- Hamzaçebi, C., & Kutay, F. (2004). Yapay sinir ağları ile Türkiye elektrik enerjisi tüketiminin 2010 yılına kadar tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19(3).
- Han, J., Kamber, M., & Pei, J. (2011). Data mining: Concepts and techniques (3rd ed.). Morgan Kaufmann. Erişim Adresi: <https://www.elsevier.com/books/data-mining/han/978-0-12-381479-1>.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning: Data mining, inference, and prediction* (2nd ed.). New York, NY: Springer.
- Hatunoğlu, E. E., & Eldeniz, F. (2012). 2000 yılı sonrası Türk tarım sektöründe yapısal dönüşüm politikaları. *Sayıştay Dergisi*, (86), 27-56.
- Hekimoğlu, B., & Altındağ, M. (2006). *Tarımın ve tarımsal göstergelerin; Ülkemizdeki ve Samsun ilimizdeki gelişim seyri*. Samsun Valiliği Tarım İl Müdürlüğü Strateji Geliştirme Birimi.
- Hornik, K., Stinchcombe, M., & White, H. (1989). Multilayer feedforward networks are universal approximators. *Neural Networks*, 2(5), 359-366.
- Işık, H. B., Kılınç, E. C., & Bilgin, O. (2015). Tarım kredilerinin tarımsal üretim üzerindeki etkisi. In *EY International Congress on Economics II (EYC2015)*, November 5–6, 2015, Ankara, Turkey (No. 250). Ekonomik Yaklaşım Association.
- İnan, İ. H., Gülçubuk, B., Ertuğrul, C., Kantürer, E., Baran, E. A., & Dilmen, Ö. (2000). Türkiye’de tarımda kırsal kesim örgütlenmesi. *Türkiye Ziraat Mühendisliği V. Teknik Kongresi*, 1, 17-21.
- Jolliffe, I. T. (2002). *Principal component analysis* (2nd ed.). New York, NY: Springer.
- Kalkınma Bakanlığı. (2012). *2012 yılı programı*, Ankara.
- Karacan, A. R. (1991). *Tarım işletmelerinin finansmanı ve tarımsal kredi* (Yayın No. 498). İzmir: Ege Üniversitesi Ziraat Fakültesi Yayınları.
- Karahan, M. (2015). A case study on forecasting of tourism demand with artificial neural network method. Suleyman Demirel University *The Journal of Faculty of Economics and Administrative Sciences*, 20(2), 195-209.
- Karluk, S. R. (2009). *Cumhuriyet'in ilanından günümüze Türkiye ekonomisinde yapısal dönüşüm*. Beta.
- Kavcıoğlu, Ş. (2019). Kurumsal kredi skorlamasında klasik yöntemlerle yapay sinir ağı karşılaştırması. *İstanbul İktisat Dergisi*, 69(2), 207-246.
- Kaya, E., & Kadanalı, E. (2022). The nexus between agricultural production and agricultural loans for banking sector groups in Turkey. *Agricultural Finance Review*, 82(1), 151-168.
- Kaynar, O., Arslan, H., Görmez, Y., & Işık, Y. E. (2018). Makine öğrenmesi ve öznetelik seçim yöntemleriyle saldırı tespiti. *Bilişim Teknolojileri Dergisi*, 11(2), 175-185.
- Kazgan, G. (2003). *Tarım ve gelişme*. İstanbul: İstanbul Bilgi Üniversitesi Yayınları.

- Khan, A. R., Tewari, S. K., & Shukla, A. N. (2007). Effect of liberalization on institutional agricultural credit flow and its relationship with average cost of cultivation in Indian agriculture. *Agricultural Economics Research Review*, 20(2), 227-334.
- Kılıçalp, E., İnan, A. A., & Subaşı, H. (2001). GAP'ın Diyarbakır ilindeki tarıma dayalı imalat sanayindeki gelişme sürecine etkileri. In *II. GAP ve Sanayi Kongresi Bildiriler El Kitabı* (pp. 29–30). Diyarbakır: TMMOB Makina Mühendisleri Odası.
- Kırca, S., Canatan, G., & Güneş, V. (2022). Makine Öğrenmesi Yaklaşımı ile Acente Kredi Riski Hesaplama. *Bilişim Teknolojileri Dergisi*, 15(2), 159-166.
- Koç, A. A., Yu, T. E., Kıymaz, T., & Sharma, B. P. (2019). Effects of government supports and credits on Turkish agriculture: A spatial panel analysis. *Journal of Agribusiness in Developing and Emerging Economies*, 9(4), 391-401.
- Kotsiantis, S. B. (2013). Decision trees: A recent overview. *Artificial Intelligence Review*, 39(4), 261–283. <https://doi.org/10.1007/s10462-011-9272-4>.
- Kuhn, M., & Johnson, K. (2013). *Applied Predictive Modeling*. Springer.
- Kutner, M. H., Nachtsheim, C. J., Neter, J., & Li, W. (2004). *Applied Linear Statistical Models* (5th ed.). McGraw-Hill Education.
- Kutner, M. H., Nachtsheim, C. J., Neter, J., & Li, W. (2005). *Applied Linear Statistical Models*. McGraw-Hill Irwin.
- Liakos, K. G., Busato, P., Moshou, D., Pearson, S., & Bochtis, D. (2018). Machine Learning in Agriculture: A Review. *Sensors*, 18(8), 2674. <https://doi.org/10.3390/s18082674>.
- Little, R. J. A., & Rubin, D. B. (2002). *Statistical analysis with missing data* (2nd ed.). Wiley. Erişim Adresi: <https://doi.org/10.1002/9781119013563>.
- Loh, W.-Y. (2011). Classification and regression trees. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 1(1), 14–23. <https://doi.org/10.1002/widm.8>.
- Markoff, J. (2015, Ekim 10). *A learning advance in artificial intelligence rivals human abilities*. The New York Times, 10.
- Maslow, A.H. (1948). “Higher” and “lower” needs. *The Journal of Psychology*, 25(2), 433-436.
- Matsuo, Y., LeCun, Y., Sahani, M., Precup, D., Silver, D., Sugiyama, M., ... & Morimoto, J. (2022). Deep learning, reinforcement learning, and world models. *Neural Networks*, 152, 267-275.
- Meyer, R.L. (2013). Microcredit and Agriculture: Challenges, Successes and Prospects. In: Gueyie, JP., Manos, R., Yaron, J. (eds) *Microfinance in Developing Countries*. Palgrave Macmillan, London. https://doi.org/10.1057/9781137301925_10.
- Monkeylearn. (2021). An Introduction to Machine Learning. monkeylearn.com: <https://monkeylearn.com/machine-learning/>.
- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2021). *Introduction to linear regression analysis* (6th ed.). Hoboken, NJ: Wiley.
- Mülayım, Z. G. (1995). *Kooperatifçilik*. Ankara: Yetkin Basımevi.
- Narin, M. (2011). Türkiye ekonomisinin dinamikleri: Politika arayışları, 1980'li yıllardan sonra tarım politikalarındaki değişiklikler. *Ekonomik Yaklaşım Kongresi*, Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi, Ankara.

- Obilor, S. I. (2013). The impact of commercial banks' credit to agriculture on agricultural development in Nigeria: An econometric analysis. *International Journal of Business, Humanities and Technology*, 3(1), 85-94.
- Ogbuabor, J. E., & Nwosu, C. A. (2017). The impact of deposit money bank's agricultural credit on agricultural productivity in Nigeria: Evidence from an error correction model. *International Journal of Economics and Financial Issues*, 7(2), 513-517.
- Organisation for Economic Co-operation and Development. (2011). *Evaluation of Agricultural Policy Reforms in Turkey*. OECD Publishing.
- Oya, C. (2007). Kalkınmakta olan ülkelerde çiftçilere sopa ve havuç: Kuramda ve uygulamada tarımsal neoliberalizm. *Neoliberalizm Muhalif Bir Seçki, Hazırlayan: Alfredo Saad-Filho, Deborah Johnston*, 213-224.
- Ozdemir, G., & Efe, A. (2013). Governance at The Regional Development Agencies In Turkey. *International Journal of Ebusiness and Egoovernment Studies*, 5(2), 59-69.
- Özçelik, A., Güneş, E., & Artukoğlu, M. M. (2005). Türkiye'de tarımsal kredi: Sözleşmeli tarım ve üretici örgütleri üzerinden kredi uygulamaları. *Türkiye Ziraat Mühendisliği 6. Teknik Kongresi*, 3-7 Ocak, 961-985.
- Özdemir, V. (2014). Türkiye'de planlı kalkınma deneyimleri. *Marmara Üniversitesi*, 23-24.
- Özertan, G. (2013). Türkiye tarım sektöründe yapısal dönüşüm ve teknoloji kullanımının rolü (No. 2013/01).
- Öztemel, E. (2003). *Yapay sinir ağları*. İstanbul: Papatya Yayıncılık.
- Öztemel, E. (2006). *Yapay Sinir Ağları*, Papatya Yayıncılık, 2. Baskı, İstanbul: Papatya Yayıncılık
- Öztürk, Ş. (2008). Kırsal yoksulluk ve neo-liberal ekonomi politikaları. *Journal of International Social Research*, 1(5).
- Pandey, U. K. (2008). *Agricultural finance*. National Science Digital Library. Erişim 06 Aralık 2023, <http://nsdl.niscair.res.in/jspui/bitstream/123456789/498/1/PDF%20revised%20AGRICULTURAL%20FINANCE-corrected.pdf> sayfasından erişilmiştir.
- Parasız, İ. (2005). *Kalkınma ekonomisi*, Bursa: Ezgi Kitabevi.
- Parasız, M. İ. (2000). *Para, banka ve finansal piyasalar*. Bursa: Ezgi Kitabevi Yayınları.
- Patro, S. G. K., & Sahu, K. K. (2015). Normalization: A preprocessing stage. arXiv preprint arXiv:1503.06462. Erişim Adresi: <https://arxiv.org/abs/1503.06462>.
- Perçin, N. (1999). *Temel kredi bilgileri*. İstanbul: Demirbank Eğitim Müdürlüğü Yayınları.
- Pinilla, V., & Willebald, H. (2018). Agricultural development in the world periphery. *A global economic history approach*. Cham, Switzerland: Palgrave Macmillan.
- Quan, Q., Hao, Z., Xifeng, H., & Jingchun, L., (2020). Research on water temperature prediction based on improved support vector regression. *Neural Comput. Appl.* 4. <https://doi.org/10.1007/s00521-020-04836-4>.
- Quinlan, J. R. (1986). Induction of decision trees. *Machine learning*, 1, 81-106.
- Quinlan, J. R. (1996). Improved use of continuous attributes in C4.5. *Journal of Artificial Intelligence Research*, 4, 77-90.
- Rasmussen, C. E., & Williams, C. K. I. (2006). *Gaussian Processes for Machine Learning*. MIT Press.

- Rath, S., Tripathy, A., & Tripathy, A. R. (2020). Prediction of new active cases of coronavirus disease (COVID-19) pandemic using multiple linear regression model. *Diabetes & metabolic syndrome: clinical research & reviews*, 14(5), 1467-1474.
- Reddy, Y. C. A. P., Viswanath, P., & Reddy, B. E. (2018). Semi-supervised learning: A brief review. *Int. J. Eng. Technol*, 7(1.8), 81.
- Rokach, L. (2010). Ensemble-based classifiers. *Artificial Intelligence Review*, 33(1-2), 1-39. <https://doi.org/10.1007/s10462-009-9124-7>.
- Russo, C. (2007). Deficiency payments and market power: Effects of imperfect competition on welfare distribution and decoupling. *American Agricultural Economics Association Annual Meeting*, Portland, OR.
- Sahin, İ. S. M. A. İ. L. (2014). Prediction of surface roughness of Al/SiC composite material with artificial neural networks yapay sinir ağı ile AL/SiC kompozit malzemenin yüzey pürüzlülüğünün tahmini. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 29(1).
- Saleem, M. A., & Jan, F. A. (2011). The impact of agricultural credit on agricultural productivity in Dera Ismail Khan (District) Khyber Pakhtonkhawa Pakistan. *European Journal of Business and Management*, 3(2), 38-44.
- Sarı, M. (2000). *Tarım kredi kooperatiflerinin finansman ve kredilendirme sorunlarının çözümüne yönelik bir model* (Yüksek lisans tezi). Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 98913)
- Sarı, S. (2020). *Banka kredilerinde sektörel yoğunlaşma ve kredi riski ilişkisi: Türkiye örneği 2007-2018* (Doktora tezi). Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 654701)
- Schafer, J. L., & Graham, J. W. (2002). Missing data: Our view of the state of the art. *Psychological Methods*, 7(2), 147-177. Erişim Adresi: <https://doi.org/10.1037/1082-989X.7.2.147>.
- Selçuk, D. (2015). *Bireysel kredilerin ekonomik büyüme üzerindeki etkisi: Türkiye örneği* (Doktora tezi). Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 417900)
- Sevinç, D. (2021). Türkiye'de takipteki banka kredileri ile makroekonomik faktörler arasındaki ilişki. *Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 8(2), 609-629.
- Shannon, C. E. (1948). A mathematical theory of communication. *The Bell System Technical Journal*, 27(3), 379-423.
- Sharma, H., & Kumar, S. (2016). A survey on decision tree algorithms of classification in data mining. *International Journal of Science and Research (IJSR)*, 5(4), 2094-2097.
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and Computing*, 14(3), 199-222.
- Şekeroğlu, S. (2010). *Hizmet sektöründe bir veri madenciliği uygulaması* (Yüksek lisans tezi). Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 293982)
- Takan, M., & Boyacıoğlu, M. A. (2011). *Bankacılık: Teori, uygulama ve yöntem*. Ankara: Nobel Akademik Yayıncılık.
- Tan, S., Hasdemir, M., & Everest, B. (2015). Türkiye'de tarımsal destekleme politikaları [Agricultural support policies in Turkey]. *International Conference on Eurasian Economies*, 266-270.

- Tarım ve Orman Bakanlığı. (2022). *Faaliyet raporu: 2022 mali yılı*. Erişim adresi: https://www.tarimorman.gov.tr/SGB/Belgeler/Bakanlik_Faaliyet_Raporlari/TOB%202022%20YILI%20İDARE%20FAALİYET%20RAPORU.pdf
- Türkiye Cumhuriyeti. (2006). *Tarım Kanunu* (Kanun No. 5488). Resmî Gazete, 26149, 25 Nisan 2006.
- Taşdemir, Ş., Neşeli, S., & Yıldız, S. (2009). Prediction of surface roughness on turning with artificial neural network. *Journal of Engineering and Architecture Faculty of Eskişehir Osmangazi University*, 22(9), 65-75.
- Taşkıran, R., & Özudoğru, H. (2010). Türkiye'de tarımsal kredi uygulamaları. *Gazi Üniversitesi Ticaret ve Turizm Eğitim Fakültesi Dergisi*(1), 150-163.
- TCMB. (2022). <https://www.tcmb.gov.tr/>.
- Tevfik, A. T. (2005). Sermaye Yapısı Kararları ve Efektif Vergi Oranın Sıfır Olduğu Firmalarda Optimal Sermaye Yapısının Belirlenmesi. *Manas Üniversitesi Sosyal Bilimler Dergisi*, 7(14), 116-134. <http://dergipark.gov.tr>.
- TGDF. (2023). 2023 Dış Ticaret Verileri. 26.12.2023 tarihinde <https://www.tgdf.org.tr/tgdf-dis-ticaret-bulteni-2023/> adresinden edinilmiştir.
- Thirlwall, A. P. (2003). *Growth and development: With special reference to developing economies* (7th ed.). Hampshire: Palgrave Macmillan.
- Tigrak, U., Taşgetiren, N., Bozan, E., Gül, G., Demirci, E., Sarıbiyık, H., & Aktaş, M. S. (2020). Büyük veri işleme ve analizi teknikleri kullanılarak bankacılık sektöründe kredi kullanımı ihtiyacı tahmini: Durum çalışması. *EasyChair Preprint*, (4458).
- TÜİK. (2022a). Nüfus ve konut sayım istatistikleri. Türkiye İstatistik Kurumu. <https://data.tuik.gov.tr/Bulten/Index?p=Nufus-ve-Konut-Sayim-i-2021-45866>.
- TÜİK. (2022b). İşgücü istatistikleri. Türkiye İstatistik Kurumu. <https://data.tuik.gov.tr/Kategori/GetKategori?p=Nufus-ve-Demografi-109>.
- TÜİK. (2022c). İşgücü istatistikleri. Türkiye İstatistik Kurumu. <https://data.tuik.gov.tr/Kategori/GetKategori?p=Is-tihdam,-Issizlik-ve-Ucret-108>.
- Tuna, Y. (1993). *Tarımda verimlilik artışının ekonomik sonuçları: Türkiye ile ilgili bir değerlendirme*. Milli Prodüktivite Merkezi.
- Tunaboş, O. (1977). *Orta vadeli kredi uygulaması ve kaynakları* (No. 3). İstanbul: İstanbul Bankası T.A.Ş.
- Turhan, Ş., & Erdal, B. (2022). Ekonomik büyüme ve tarımsal istihdam. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 5(1), 66-74. <https://doi.org/10.47495/okufbed.972239>.
- Türkiye Cumhuriyeti Cumhurbaşkanlığı Strateji ve Bütçe Başkanlığı. (2024). 2006-2024 Merkezi yönetim bütçe gerçekleştirmeleri ve beklentiler raporu. Erişim adresi: <https://www.sbb.gov.tr/wp-content/uploads/2024/07/2024-Merkezi-Yonetim-Butce-Gercekleştirmeleri-ve-Beklentiler-Raporu.pdf>.
- TÜSİAD. (2022). Gıda ve tarım sektörünün geleceğini ele alan bir konferans düzenledi. <https://tusiad.org/tr/tum/item/7021-tusiad-gida-ve-tarim-sektorunun-gelecegini-ele-alan-bir-konferans-duzenledi>.
- Vakıfbank. (2021). Tarihimiz, 02 Şubat 2024 tarihinde <https://www.vakifbank.com.tr/hakkimizda.aspx?pageID=182> sayfasından erişilmiştir.

- Williams, C. K. I., & Barber, D. (1998). Bayesian classification with gaussian processes. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 20(12), 1342-1351.
- WorldBank. (2023), Girdi Değişkenleri Verileri, <https://databank.worldbank.org/>
- Yanık, H. (2008). *Bankacılık Sektörünün Ekonomik Kalkınmaya Etkileri* (Yüksek lisans tezi). Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 219607)
- Yavuz, F. (2005). *Türkiye'de tarım* (Cilt 1). Ankara: Tarım ve Köyişleri Bakanlığı Yayınları.
- Yavuz, F., & Dilek, Ş. (2019). *Türkiye tarımına yeniden bakış*.
- Yazgı, F. E., & Olhan, E. (2017). Gelişmiş ülkeler ve Türkiye'de tarım sigortası sistemlerinin karşılaştırılması. *Tarım Ekonomisi Dergisi*, 23(2), 231-239. <https://doi.org/10.24181/tarekoder.369424>.
- Yıldız, E., & Oğuzhan, A. (2007). Türkiye'de uygulanan para politikalarının tarımsal üretime etkisi: Model denemesi. *Trakya Üniversitesi Sosyal Bilimler Dergisi*, 9(2), 206-225.
- Yılmaz, H., & Köknaroğlu, H. (2007). Avrupa Birliği ortak tarım politikasına uyum sürecinde Türkiye'de izlenen hayvancılık politikalarının değerlendirilmesi. *V. Zootehni Bilim Kongresi*, 5-8.
- Yılmaz, S. (2011). *Ticari bankalarda kredi portföyü ve kredi riski yönetimi-bankacılık sektöründe bir uygulama* (Yüksek lisans tezi). Yükseköğretim Kurulu Ulusal Tez Merkezi'nden edinilmiştir. (Tez No. 277345)
- Yücememiş, B. T., & Sözer, İ. (2011). Bankalarda takipteki krediler: Türk bankacılık sektöründe takipteki kredilerin tahminine yönelik bir model uygulaması. *Finansal Araştırmalar ve Çalışmalar Dergisi*, 3(5), 43-56.
- Zhang, Z. (2016). Missing data imputation: focusing on single imputation. *Annals of Translational Medicine*, 4(1).
- Zhang, C., Wei, H., Zhao, X., Liu, T., & Zhang, K. (2016). A Gaussian process regression based hybrid approach for short-term wind speed prediction. *Energy Conversion and Management*, 126, 1084-1092.
- Ziraat Bankası. (2010). *Sorularla tarımsal bankacılık*. Ankara: T.C. Ziraat Bankası A.Ş. Eğitim Daire Başkanlığı Eğitim Yayınları.
- Ziraat Bankası. (2013). Tarımsal Krediler Uygulama Esas ve Usulleri. *T.C. Ziraat Bankası A.Ş.*
- Ziraat Bankası. (2018). Ziraat Bankası Tarım Girişimci, 17 Ocak 2024 tarihinde <http://www.ziraatbank.com.tr/tr/girisimci/tarim> adresinden erişilmiştir.
- Ziraat Bankası. (2018a). Bankamız Tarihçesi, 17 Şubat 2024 tarihinde <https://www.ziraatbank.com.tr/tr/bankamiz/hakkimizda/bankamiz-tarihcesi> adresinden erişilmiştir.
- Ziraat Bankası. (2021). Bankamız Tarihçesi, 02 Şubat 2024 tarihinde <https://www.ziraatbank.com.tr/tr/bankamiz/hakkimizda/bankamiz-tarihcesi> sayfasından erişilmiştir.
- ZMO. (2021). Doğrudan gelir desteği: Tarımsal destek mi, yoksulluk yardımını mı? http://www.zmo.org.tr/genel/bizden_detay.php?kod=147&tipi=5&sube=0.

ÖZ GEÇMİŞ

Abdurrahim KÖPRÜCÜ, [REDACTED] doğdu. İlk, orta ve lise eğitimlerini Bayburt'ta tamamladıktan sonra 2013 yılında Uludağ Üniversitesi İktisadi ve İdari Bilimler Fakültesinde Lisans eğitime başladı. 2018 yılında Lisans derecesini aldı. 2022 yılında Bayburt Üniversitesi, Lisansüstü Eğitim Enstitüsü Organik Tarım İşletmeciliği Anabilim Dalı'nda Yüksek Lisans eğitime başladı.

