

**T.C.  
NECMETTİN ERBAKAN ÜNİVERSİTESİ  
SOSYAL BİLİMLERİ ENSTİTÜSÜ  
MALİYE ANABİLİM DALI  
MALİYE BİLİM DALI**

**HANEHALKI YOKSULLUK DÜZEYİNİN MAKİNE  
ÖĞRENMESİ VE YAPAY SİNİR AĞLARI İLE  
TAHMİNİ: TÜRKİYE ÖRNEĞİ**

**BEYZANUR ABACI**

**YÜKSEK LİSANS TEZİ**

**DANIŞMAN:**

**PROF. DR. ALTUĞ MURAT KÖKTAŞ**

**KONYA-2024**

**T.C.  
NECMETTİN ERBAKAN ÜNİVERSİTESİ  
SOSYAL BİLİMLERİ ENSTİTÜSÜ  
MALİYE ANABİLİM DALI  
MALİYE BİLİM DALI**

**HANEHALKI YOKSULLUK DÜZEYİNİN MAKİNE  
ÖĞRENMESİ VE YAPAY SİNİR AĞLARI İLE  
TAHMİNİ: TÜRKİYE ÖRNEĞİ**

**BEYZANUR ABACI**

**YÜKSEK LİSANS TEZİ**

**DANIŞMAN:**

**PROF. DR. ALTUĞ MURAT KÖKTAŞ**

**KONYA-2024**

 KONYA	T.C. NECMETTİN ERBAKAN ÜNİVERSİTESİ Sosyal Bilimler Enstitüsü Müdürlüğü	 NECMETTİN ERBAKAN ÜNİVERSİTESİ KONYA SOSYAL BİLİMLER ENSTİTÜSÜ
--	---	---

## BİLİMSEL ETİK SAYFASI

Öğrencinin	Adı Soyadı	BEYZANUR ABACI		
	Numarası	21813501002		
	Ana Bilim / Bilim Dalı	Maliye/ Maliye		
	Programı	Tezli Yüksek Lisans	✓	
		Doktora		
Tezin Adı	HANEHALKI YOKSULLUK DÜZEYİNİN MAKİNE ÖĞRENMESİ VE YAPAY SİNİR AĞLARI İLE TAHMİNİ: TÜRKİYE ÖRNEĞİ			

Bu tezin hazırlanmasında bilimsel etiğe ve akademik kurallara özenle riayet edildiğini, tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, ayrıca tez yazım kurallarına uygun olarak hazırlanan bu çalışmada başkalarının eserlerinden yararlanılması durumunda bilimsel kurallara uygun olarak atıf yapıldığını bildiririm.

**BEYZANUR ABACI**

**İmzası**

## ÖZET

<b>Öğrencinin</b>	<b>Adı Soyadı</b>	<b>BEYZANUR ABACI</b>		
	<b>Numarası</b>	<b>21813501002</b>		
	<b>Ana Bilim / Bilim Dalı</b>	<b>Maliye/ Maliye</b>		
	<b>Programı</b>	<b>Tezli Yüksek Lisans</b>	<input checked="" type="checkbox"/>	
		<b>Doktora</b>	<input type="checkbox"/>	
	<b>Tez Danışmanı</b>	<b>Prof. Dr. Altuğ MURAT KÖKTAŞ</b>		
<b>Tezin Adı</b>	<b>HANEHALKI YOKSULLUK DÜZEYİNİN MAKİNE ÖĞRENMESİ VE YAPAY SİNİR AĞLARI İLE TAHMİNİ: TÜRKİYE ÖRNEĞİ</b>			

Hanehalkı yoksulluk düzeyinin tahmini, bir ülkenin sosyo-ekonomik durumunu anlamaya yardımcı olmaktadır. Bu tahminler, ülkedeki yoksulluğun ne kadar yaygın olduğunu ve hangi bölgelerde daha fazla olduğunu gösterir. Bu bilgi, ülkede yoksulluğu azaltmak için yapılacak çalışmaların, geliştirilecek politikaların daha etkili olmasını sağlayabilir. Ayrıca, hanehalkı yoksulluk düzeyinin tahmini, ülkedeki insanların yaşam koşulları hakkında da bilgi vermektedir. Bu bilgi, ülkenin sosyal ve ekonomik gelişimine ilişkin önemli bir göstergedir. Makine öğrenmesi algoritmalarının kullanılması, bu tahminleri yaparken daha doğru sonuçlar elde edilmesini sağlamaktadır. Bu algoritmalar, verileri analiz ederek benzer özelliklere sahip hanehalklarının yoksulluk düzeyini tahmin edebilmektedir. Bu sayede, hanehalkı yoksulluk düzeyinin tahminlerinde daha yüksek bir doğruluk oranına ulaşılabilmektedir. Çalışma kapsamında TÜİK tarafından hazırlanan Hanehalkı Bütçe Anketi 2019 verisi ile 11,521 hanenin sosyo-ekonomik durumları ve yaşanan hane değişkenleri üzerinden bir yoksulluk düzeyi sınıflandırma çalışması yapılmıştır. Çalışmada 9 adet makine öğrenmesi modeli ve 1 adet yapay sinir ağı kullanılmış olup, elde edilen çıktıların karşılaştırmaları yer almaktadır.

LightGBM, doğruluk ve F1 skoru açısından en iyi performansı sergilerken, eğitim süresi de oldukça makul düzeydedir. Bu bulgular, yoksulluk sınıflandırması için en uygun algoritmanın LightGBM olduğunu göstermektedir. Bu süreçte, özellik önemliliği analizi, modellerin performansını artırmada ve yorumlana bilirlğini sağlamada kritik bir rol oynamaktadır. Araştırmada seçilen algoritmaların özellik önemliliği incelendiğinde, en sık tekrar eden özelliğin izafî kira, hanede yapılan tasarrufları değerlendirme şekli ve hanede kredi kartı kullanan fert olup olmadığını ölçen değişkenin olduğu görülmektedir.

**Anahtar Kelimeler:** Hanehalkı, Makine öğrenmesi, Yapay sinir ağları, Yoksulluk.

## ABSTRACT

<b>Authors</b>	<b>Name and Surname</b>	<b>BEYZANUR ABACI</b>		
	<b>Student Number</b>	<b>21813501002</b>		
	<b>Department</b>	<b>Public Finance / Public Finance</b>		
	<b>Study Programme</b>	<b>Master's Degree (M.A.)</b>	<input checked="" type="checkbox"/>	
		<b>Doctoral Degree (Ph.D.)</b>	<input type="checkbox"/>	
	<b>Supervisor</b>	<b>Professor. ALTUĞ MURAT KÖKTAŞ</b>		
<b>Title of the Thesis/Dissertation</b>	<b>ESTIMATION OF HOUSEHOLD POVERTY LEVEL VIA MACHINE LEARNING AND ARTIFICIAL NEURAL NETWORKS: THE CASE OF TÜRKİYE</b>			

Estimating the household poverty level helps to understand the socio-economic situation of a country. These estimates show how widespread poverty is in a country and in which regions it is more prevalent. This information can make the studies and policies to be developed to reduce poverty in the country more effective. Moreover, the estimation of household poverty level also provides information about the living conditions of people in the country. This information is an important indicator of the social and economic development of the country. The use of machine learning algorithms provides more accurate results in making these estimates. By analyzing the data, these algorithms can estimate the poverty level of households with similar characteristics. In this way, a higher accuracy rate can be achieved in estimating the household poverty level. Within the scope of the study, a poverty level classification study was conducted based on the Household Budget Survey 2019 data prepared by TurkStat and the socio-economic status and household variables of 11,521 households. In the study, 9 machine learning models and 1 artificial neural network were used and comparisons of the outputs obtained are included.

LightGBM performs the best in terms of accuracy and F1 score, while the training time is quite reasonable. These findings suggest that LightGBM is the most suitable algorithm for poverty classification. In this process, feature importance analysis plays a critical role in improving the performance and interpretability of the models. When the feature significance of the algorithms selected in the study is analyzed, it is seen that the most frequently recurring feature is the relative rent, the way of evaluating household savings and the variable measuring whether there is a credit card user in the household.

**Keywords:** Household, Machine learning, Artificial neural networks, Poverty.

## İÇİNDEKİLER

<b>BİLİMSEL ETİK SAYFASI .....</b>	<b>ii</b>
<b>ÖZET .....</b>	<b>iii</b>
<b>ABSTRACT.....</b>	<b>v</b>
<b>İÇİNDEKİLER.....</b>	<b>vii</b>
<b>KISALTMALAR .....</b>	<b>x</b>
<b>ŞEKİLLER LİSTESİ .....</b>	<b>xii</b>
<b>TABLolar LİSTESİ .....</b>	<b>xiii</b>
<b>ÖN SÖZ .....</b>	<b>xiv</b>
<b>GİRİŞ.....</b>	<b>1</b>
<b>BİRİNCİ BÖLÜM .....</b>	<b>5</b>
<b>YOKSULLUK ve YOKSULLUĞA İLİŞKİN .....</b>	<b>5</b>
1.1. Yoksulluk Kavramı .....	5
1.2. Yoksulluk Türleri .....	6
1.2.1. Mutlak Yoksulluk .....	6
1.2.2. Göreli Yoksulluk.....	6
1.2.3. Öznel (Subjektif) Yoksulluk .....	7
1.2.4. İnsani Yoksulluk .....	7
1.2.5. Gelir Yoksulluğu.....	8
1.2.6. Kırsal ve Kentsel Yoksulluk .....	9
1.2.7. Geçici ve Kronik Yoksulluk.....	9
1.2.8. Çok Boyutlu Yoksulluk.....	10
1.3. Yoksulluk Ölçümünde Yaklaşımlar .....	10
1.3.1. Yoksulluk Sınırı .....	11
1.3.2. Hanehalkı Kullanılabilir (Harcanabilir) Fert Geliri .....	12
1.3.3. Eşdeğerlik Ölçeği Yaklaşımı.....	12
1.3.4. Asgari Kalori Alımı Yaklaşımı .....	13
1.3.5. Gıda Oranı Yaklaşımı .....	14
1.3.6. Temel İhtiyaçlar Maliyeti Metodu .....	14
1.3.7. Gıda Enerjisi Alımı Metodu.....	14

1.3.8.	Günlük Dolar Bazlı Yoksulluk Sınırı.....	15
1.3.9.	Ravallion Metodu: En Alt En Üst Yoksulluk Sınırı.....	16
1.4.	Yoksulluk Ölçümünde Endeksler .....	16
1.4.1.	Kafa Sayısı Endeksi .....	17
1.4.2.	Yoksulluk Açığı .....	17
1.4.3.	Atkinson Endeksi .....	18
1.4.4.	Sen Endeksi.....	18
1.4.5.	Watts Endeksi .....	19
1.4.6.	Kakwani Endeksi .....	20
1.4.7.	Sen, Shorracks, Thon Endeksi .....	20
1.4.8.	Takayama Endeksi .....	21
1.4.9.	Theil, Bourguignon Endeksi .....	21
1.4.10.	Çok Boyutlu Yoksulluk Endeksi.....	22
1.4.11.	Eşitsizliğe Uyarlanmış İnsani Gelişme Endeksi.....	22
1.5.	Türkiye'deki Mevcut Yoksulluk Durumu ve Göstergeleri .....	22
	<b>İKİNCİ BÖLÜM.....</b>	<b>28</b>
	<b>LİTERATÜR TARAMASI.....</b>	<b>28</b>
	<b>ÜÇÜNCÜ BÖLÜM.....</b>	<b>44</b>
	<b>YAPAY ZEKA ÇERÇEVESİ VE UYGULAMA .....</b>	<b>44</b>
3.1.	Yapay Zeka Modelleri.....	44
3.1.1.	Destek Vektör Makinesi.....	45
3.1.2.	K En Yakın Komşu Algoritması .....	45
3.1.3.	Naive Bayes (Gaussian) Algoritması .....	46
3.1.4.	Karar Ağacı Algoritması .....	47
3.1.5.	Rasgele Orman Algoritması.....	47
3.1.6.	XG Boost Algoritması.....	48
3.1.7.	Light GBM Algoritması.....	48
3.1.8.	Ada Boost Algoritması.....	48
3.1.9.	Gradyan Arttırma Algoritması .....	49
3.1.10.	Çok Katmanlı Algılayıcı (Multilayer Perceptron-MLP) .....	49
3.2.	Metodoloji.....	50

3.2.1. Veri.....	50
3.2.2. Yöntem.....	57
3.2.3. Analiz.....	60
3.2.3.1. Sınıflandırma Algoritmaları .....	60
• Destek Vektör Makineleri (SVM).....	62
• K-En Yakın Komşu (KNN) .....	62
• Naive Bayes (Gaussian) .....	63
• Karar Ağacı .....	63
• Rasgele Orman.....	63
• XG Boost.....	64
• LightGBM.....	64
• AdaBoost.....	65
• Gradyan Arttırma .....	65
• Çok Katmanlı Algılayıcı (MLP) .....	65
3.2.3.2. Özellik Önemliliği.....	68
<b>SONUÇ .....</b>	<b>76</b>
<b>KAYNAKÇA.....</b>	<b>85</b>

## KISALTMALAR

<b>AdaBoost.</b>	Adaptive Boosting
<b>ASH.</b>	Açık Sokak Haritası
<b>CDR.</b>	Call Detail Records
<b>CNN.</b>	Evrişimli Sinir Ağı
<b>DVM.</b>	Destek Vektör Makinesi
<b>GLM.</b>	Genelleştirilmiş Lineer Model
<b>GLSS 6.</b>	Gana Yaşam Standartları Araştırması Altıncı Tur (Ghana Living Standards Survey Round Six)
<b>GSYİH.</b>	Gayri Safi Yurt İçi Hasıla
<b>HIES.</b>	Household Income and Expenditure Survey
<b>KNN.</b>	K En Yakın Komşu
<b>LAD</b>	En Küçük Mutlak Sapma
<b>LASSO</b>	En Küçük Mutlak Küçültme ve Seçim Operatörü
<b>LSMS.</b>	Yaşam Standartları Ölçüm Çalışması (Living Standards Measurement Study)
<b>MLP.</b>	Çok Katmanlı Algılayıcı (Multi Layer Perceptron)
<b>NDVI</b>	Normalized Difference Vegetation Index
<b>OPHI.</b>	Oxford Yoksuluk ve İnsani Gelişme Girişimi (Oxford Poverty and Human Development Initiative)
<b>PC.</b>	Pearson Korelasyon (Pearson Correlation)

<b>PMT.</b>	Proxy-Means Testi
<b>PPI.</b>	Yoksulluk Olasılık Endeksi (Poverty Probability Index)
<b>PSLM.</b>	
<b>RO.</b>	Rasgele Orman
<b>TBA.</b>	Temel Bileşenler Analizi
<b>TÜİK.</b>	Türkiye İstatistik Kurumu
<b>XGBoost.</b>	Extreme Gradient Boosting
<b>YSA.</b>	Yapay Sinir Ağı

## ŞEKİLLER LİSTESİ

Şekil 3.2.1. Karar Ağacı Özellik Önemliliği .....	68
Şekil 3.2.2. Rasgele Orman Özellik Önemliliği .....	70
Şekil 3.2.3. Gradyan Arttırma Özellik Önemliliği.....	71
Şekil 3.2.4. XGBoost Özellik Önemliliği .....	72
Şekil 3.2.5. AdaBoost Özellik Önemliliği .....	73
Şekil 3.2.6. LightGBM Özellik Önemliliği .....	74

## TABLULAR LİSTESİ

Tablo 1.5.1. Eşdeğer Hanehalkı Kullanılabilir Fert Gelirine Göre Hesaplanan Yoksulluk Oranı (%), 2017-2023 .....	24
Şekil 1.5.2. Satınalma Gücü Paritesi (SGP) Kullanılarak Hesaplanan Gelire Dayalı Görelî Yoksulluk Sınırına Göre Yoksulluk Oranı 2006-2023.....	26
Tablo 3.2.1. Çalışmada kullanılan değişken adları ve açıklamaları .....	51
Tablo 3.2.2. Analiz sonucunda elde edilen sınıflandırma algoritmalarının başarıları ve karşılaştırmaları.....	61

## ÖN SÖZ

Yoksulluk, sadece sayıların, istatistiklerin ya da grafiklerin dünyasında var olan bir olgu değil; aksine her biri ayrı bir hikâye taşıyan insanların yaşadığı somut bir gerçekliktir. Bu tez, yoksulluğun ciddiyetini anlamak ve bu karmaşık sorunun farklı yönlerini ele alarak çözüm yolları bulmak amacıyla hazırlandı. Her bir veri noktasının ardında, zor şartlar altında hayatta kalmaya çalışan bir aile, umutlarını yitirmemek için mücadele eden bir birey var. Her analiz, her bulgu, yoksulluğun acımasız gerçekleriyle yüzleşen insanların sesidir. Bu sınavı geçebilmemiz için sadece akademik bilgilerin değil, aynı zamanda empati, merhamet ve dayanışmanın da gerekliliğine inanıyorum. Tezimin bu amaca hizmet etmesini ve yoksullukla mücadelede bir nebze de olsa fark yaratmasını umuyorum.

İleri görüşlülüğü ile benim yolumu aydınlatan değerli danışman hocam Prof. Dr. Altuğ Murat KÖKTAŞ'a, maddi-manevi destekleri, ilgileri ve sabırları için aileme, sonsuz motivasyonları ve anlayışlarıyla yanımda olan sevdiklerime gönülden teşekkürlerimi sunarım. Onların inancı ve desteği, bu süreci mümkün kılan en önemli etkenlerdi.

Umuyorum ki bu çalışma, yoksulluğun sadece bir problem değil, çözülmeyi bekleyen bir insanlık sorunu olduğunun fark edilmesine katkı sağlar. Her birimizin bu sorunun çözümünde bir rolü olduğunu unutmadan, daha adil ve merhametli bir dünya için çaba göstermek dileğiyle.

BEYZANUR ABACI

KONYA-2024

## GİRİŞ

Yoksulluk, bir kişinin veya toplumun gereksinimlerini karşılamak için gereken mal ve hizmetlere sahip olmaması sonucu ortaya çıkmaktadır. İnsanların hayat standartlarının düşük olduğu, temel ihtiyaçlarının karşılanamadığı ve insan haklarının ihlal edildiği bir durumdur. Ekonomik, sosyal ve kültürel faktörlere dayalı olarak değişebildiği gibi farklı ülkelerde farklı boyutlarda görülebilmektedir.

Günümüzde yoksulluğun tanımı, bir bireyin ya da bir hanehalkının elinde bulunan mal ve hizmetlerin, o bölgede ortalama standartların altında olduğu durum olarak yapılmaktadır. Bu tanım, bir bireyin ya da bir hanehalkının günlük yaşam için gerekli olan temel ihtiyaçlarını karşılayabilecek seviyedeki gelirin belirlenmesine yardımcı olur. Bu gelir miktarı her ülke için farklı bir değer almaktadır. Türkiye için Türkiye İstatistik Kurumu (TÜİK) tarafından her yıl açıklanan “Yıllık Ortalama Hanehalkı Kullanılabilir Geliri” hanehalkının bir yıl içinde kullanabileceği para miktarını gösterir ve hanehalkının aldığı tüm gelirlerin işyeri sigortaları, vergiler ve diğer maliyetler çıkartıldıktan sonra kalan tutarın ortalamasıdır. Bu rakam, bir hanehalkının yoksulluk sınırının altında olup olmadığını belirlemede kullanılmaktadır.

Yoksulluk, dünya genelinde birçok ülkenin ve toplumun karşılaştığı kritik bir sorundur. Yoksulluğun tespiti ve azaltılması için etkili stratejiler geliştirmek, bu sorunun çözümünde önemli bir adımdır. Makine öğrenmesi, bu stratejilerin geliştirilmesinde büyük bir potansiyele sahiptir. Yoksulluk sınıflandırması, bireylerin veya hanelerin yoksulluk durumlarını belirlemeye yönelik veri odaklı bir yaklaşımdır. Bu süreçte, özellik önemliliği analizi, modellerin performansını artırmada ve yorumlanabilirliğini sağlamada kritik bir rol oynamaktadır.

**Konu**

Birleşmiş Milletler tarafından 2030 yılına kadar tüm dünyada uygulanması gereken ve sonucunda insanların yaşamlarını iyileştirebilecekleri ve en önemlisi dünyadaki sürdürülebilirliğin artırılması için Sürdürülebilir Kalkınma Hedefleri oluşturulmuştur (UN, 2015). Bu 17 hedefte dikkat çeken nokta ise ilk hedefin yoksulluğu sona erdirmek olmasıdır. Burada yoksulluk bir ana hedef olarak karşımıza çıkmaktadır. Eski Dünya Bankası Başkanı Jim Yong Kim'in tüm insanlık tarihi düşünüldüğünde, aşırı yoksulluğu bitirebilecek ilk neslin (WB, 2015) yeni kuşak olacağını belirtmesi bu çalışmanın yapılmasının motivasyonu olmuştur.

2015 yılında dünya nüfusunun %10.1'i yani yaklaşık 740 milyon insan Dünya Bankası'nın belirlediği küresel yoksulluk sınırı olan günde 1,90 doların altında yaşamaktaydı. 2018 yılına kadar bakıldığında düşük seyirde de olsa azalan yoksulluk sınırının COVID-19 pandemisi, artış gösteren enflasyon rakamları ve Ukrayna'daki savaşın etkileri ile birlikte 2018 yılında %8.6 iken 2019 yılında %9.2'ye çıkmıştır (SDG, 2015). Burada bir istikrarlı ilerlemenin tersi durumu söz konusudur. Bu durum 1998 yılından bu yana ilk kez aşırı yoksulluğun artmasına sebep olmuştur. Çalışmanın analizinde kullanılacak olan verilerin belirlenmesinde, açıklanan bu çerçevenin önemi dikkate alındığından 2019 yılına ilişkin hanehalkı verilerinin kullanılması tercih edilmiştir.

Klasik yoksulluk hesaplamalarına bakıldığında harcama bazlı değişkenler üzerinden tahmin yapılmaktadır. Örneğin, Mutlak yoksulluk yaklaşımında belirli bir dönemde gelir veya harcamaların daha önceden belirlenmiş bir tutarın altında olan bireyler yoksul sayılmakta iken göreceli yoksulluk yaklaşımında ise yoksulluk, ülke gelirinin ya da tüketim harcamalarının bir oranı olan gerçekleşmektedir (Önder ve Şenses, 2006). Gelirler ve tüketim harcamaları para odaklı olduğu için ve hane özelliklerine ilişkin yaklaşımın daha önceden önerilmemesi sebebi ile çalışmada tüketim harcamaları değişkenleri kullanılmamış olup, haneye ilişkin değişkenler kullanılmıştır.

Yapay zeka, veri analitik ve öğrenme teknolojileri kullanarak yoksulluğun nedenlerini ve sonuçlarını analiz etmeye ve tahmin etmeye olanak tanımaktadır. Bu, daha doğru ve güncel verilere dayanarak daha etkili ve adil politika ve programlar oluşturulmasına yardımcı olabilmektedir. Ayrıca, yapay zeka bileşenleri, geniş veri kümelerini hızlı ve verimli bir şekilde analiz eder, bu da daha hızlı ve doğru kararlar verilmesini sağlamaktadır. Çalışmada yapay zeka aracılığı ile yoksulluk düzeyinin bir modeli oluşturularak, daha sonrasında bu modeller üzerinden yoksulluk sınıflandırmasına ilişkin tahminler yapılacaktır.

### **Konunun Önemi**

Yoksulluğun hesaplanmasında çeşitli regresyon modellerinin kullanıldığına önceden değinilmişti. Bu regresyon yöntemlerinden olan logit ve probit modeller, ekonomik ve demografik verilerin yoksulluğun bir fonksiyonu olarak incelendiği regresyon modelleridir. Ancak, veriler sınırlı veya eksikse, logit ve probit modeli yetersiz kalabilmektedir. Makine öğrenme yöntemleri ise, daha kapsamlı ve çok boyutlu verileri işleyebilir ve bu verileri daha doğru ve güncel tahminlere dönüştürebilmektedir. Örneğin, bir karar ağacı veya destek vektör makinesi modeli, veriler arasındaki daha karmaşık bağlantıları keşfetmeye ve tahmin yapmaya yönelik daha zorlu bir model sunabilmektedir.

Yapay sinir ağlarına (YSA) bakıldığında, yoksulluğun tahmininde etkili bir derin öğrenme yöntemi olarak görülebilmektedir. YSA, veriler arasındaki doğrusal olmayan ilişkileri daha doğru bir şekilde tahmin etmeye olanak tanımaktadır. Ayrıca, YSA, çok sayıda girdi ve çıktıya sahip verileri işlemek için tasarlanmıştır ve veri miktarına dayalı olarak öğrenme sürecine uyum sağlayabilmektedir. Bu nedenle YSA ve makine öğrenmesi algoritmaları, yoksulluğun tahmininde logit veya probit modellerine kıyasla daha geniş bir veri yelpazesi ile daha iyi sonuçlar verebilir.

YSA eğitimi için gerekli olan veri miktarı ve veriler arasındaki bağlantıların niteliği göz önünde bulundurularak seçim yapılması önemlidir. Bu seçim klasik regresyon

modellerinde doğruluk açısından eksik kalabilmektedir. Bu sebeplerden dolayı ülkenin hanehalkının yoksulluk düzeyi tahminlemede, modern yöntemlerin kullanılmasının öneminin, daha güçlü bir şekilde verilerin niteliğine uygun bir yaklaşım olarak önerülmesi gerekmektedir.

Türkiye için hanehalkı yoksulluğunun hesaplanması yöntemlerine bir yenisini eklenerek ve günümüz teknolojisine yakın bir tahmin aracı olarak yapay zeka bileşenlerinin kullanılması bu çalışmayı literatürdeki diğer çalışmalardan ayırmaktadır. Aynı zamanda yoksulluğu sadece gelir yönünden değil sosyo-ekonomik durum ve hanenin imkanları açısından da incelenip araştırmaya dahil edilmesi de yapılacak çalışmanın farklı yönlerindedir. Bu yöntem ile hanehalkı bazında yoksulluk düzeyinin tahminlenmesinde devlete bir karar destek sistemi sunmak hedeflenmektedir.

### **Amaç**

Bu çalışmanın amacı, TÜİK tarafından uygulanmış 2019 yılına ilişkin Hanehalkı Bütçe Anketi'nde (TÜİK, 2019) yer alan hanehalklarına ilişkin hane değişkenleri kullanılarak, Türkiye'de hanehalkının yoksulluk düzeyinin belirlenmesinde makine öğrenmesi ve yapay sinir ağları yöntemlerinden faydalanılarak yoksulluk tahminlemesini bir sınıflandırma problemi olarak ele almaktır. Model başarılarının karşılaştırmaları da bu çalışmanın kapsamına girmektedir.

## BİRİNCİ BÖLÜM

### YOKSULLUK ve YOKSULLUĞA İLİŞKİN

#### 1.1. Yoksulluk Kavramı

Yoksulluk, dünya çapında milyonlarca insanı etkileyen karmaşık bir konudur (Bigsten & Shimeles, 2008). Yoksulluğun azaltılmasına yönelik çeşitli yaklaşımlar arasında yoksullara gıda, istihdam ve hatta gelir sağlanması gibi doğrudan önlemler ve insanların yoksulluk döngüsünden kurtulmalarını sağlamak için eğitim, sağlık ve diğer hizmetlerin sağlanması gibi dolaylı önlemler yer almaktadır (Tilak, 2010). Bu dolaylı önlemler, yoksulluğun temel nedenlerini ele aldıkları ve bireyleri uzun vadede ekonomik durumlarını iyileştirmeleri için güçlendirdikleri için çok önemlidir. Programlar, yoksullukla yakından ilişkili olan ekonomik, sosyal ve siyasi bağları ele alarak gelir yoksulluğunu etkili bir şekilde azaltabilir ve toplumlarda sürdürülebilir değişim yaratabilir.

Yoksulluk; bireyler, hanehalkları ve toplumlar açısından farklılık gösterdiği için literatürde birçok tanım yer almaktadır. Oppenheim ve Harker'a göre yoksulluk maddi olarak, sosyal olarak ve duygusal yönden eksikliklerdir (Oppenheim ve Harker, 1996). Yoksulluk ortalama gelire sahip herhangi bir kişiye göre gıda, ısınma ve giyinmeye daha az harcama yapmaktır. Hatta bu kalemlere ne kadar harcama yapıldığı değil, yapılmadığı önemlidir. Maltus'un düşüncesine göre de hemen hemen tüm yoksulluklar göreceli olmaktadır.

Yoksulluk dar anlamda, insanların gelir seviyesinin belirli bir asgari düzeyin altında olması iken geniş anlamda; sadece maddi boyutun yanı sıra, sosyal, kültürel, fiziksel faktörleri de içerebilmekte ve kişilerin hayat kalitesini etkilemektedir. Bu kapsamda dar anlamda mutlak ve göreceli yoksulluktan, geniş anlamda ise insani yoksulluktan bahsetmek mümkündür.

## **1.2. Yoksulluk Türleri**

Yoksulluk, küresel olarak en ciddi ve karmaşık sorunlardan biridir. Bu kavram, yalnızca maddi yetersizlikleri değil, aynı zamanda sosyal, kültürel ve psikolojik boyutları da içermektedir. Yoksulluk türlerini anlamak, bu sorunun çözümü için atılacak adımları belirlemek açısından kritik öneme sahiptir. Geleneksel olarak yoksulluk, gelir düzeyi üzerinden tanımlanmıştır; ancak, modern yaklaşımlar bu sınırlamanın ötesine geçerek, yoksulluğun çok boyutlu doğasını vurgulamaktadır (Sen, 1999). Her birinin kendine özgü özellikleri ve nedenleri olan çeşitli yoksulluk türleri bulunmaktadır (Symaco, 2013). Yoksulluk türlerini; mutlak yoksulluk, görelî yoksulluk, öznel (subjektif) yoksulluk, insani yoksulluk, gelir yoksulluğu, kırsal ve kentsel yoksulluk, geçici ve kronik yoksulluk, çok boyutlu yoksulluk olarak incelemek mümkündür.

### **1.2.1. Mutlak Yoksulluk**

Mutlak yoksulluk, bireylerin veya hanehalklarının gıda, barınma, giyim ve sağlık hizmetleri dahil olmak üzere hayatta kalmak için temel ihtiyaçlarını karşılayamadığı bir yoksulluk durumunu ifade eder (Ravallion, 1998). Mutlak yoksulluk sınırı, yoksulluğun değerlendirilmesinde ve ele alınmasında çok önemli bir kavramdır. Yoksulluğun etkili bir şekilde ölçülmesi ve ele alınması için mutlak yoksulluk sınırı kavramının anlaşılması önemlidir. Bu eşik, gıda, barınma ve giyim gibi temel ihtiyaçların karşılanması için gereken asgari gelir veya tüketim düzeyini tanımlamak için kullanılmaktadır. Ayrıca, mutlak yoksulluk sınırının anlaşılması ülkeler arası karşılaştırmalara ve yoksulluğu azaltma çabalarındaki ilerlemenin izlenmesine olanak sağlamaktadır. Bu kavram, bireyleri ve toplumları yoksulluktan kurtarmaya yönelik sürdürülebilir stratejiler oluşturmak için bir temel teşkil etmektedir.

### **1.2.2. Görelî Yoksulluk**

Görelî yoksulluk sınırı yaklaşımı, bir toplumdaki yoksulluğu ölçmek için kullanılan bir yöntemdir. Nüfusu iki gruba ayırmayı içermektedir: yoksul kabul edilenler ve

edilmeyenler. Görelî yoksulluk sınırını belirlemenin yaygın bir yolu, belirli bir toplumdaki medyan gelirin bir yüzdesini hesaplamaktır. Bu eşîğın altında geliri olan bireyler veya aileler yoksulluk içinde yaşıyor olarak sınıflandırılır. Bu yaklaşım, gelir eşitsizliğinin nüfusun farklı kesimlerini nasıl etkilediğini anlamak için faydalı olmaktadır. Görelî yoksulluk, bireylerin veya ailelerin, içinde yaşadıkları toplumun genel yaşam standardına göre daha düşük bir gelir veya yaşam koşullarına sahip olması durumunu da ifade etmektedir. Bu yoksulluk, bireylerin toplumdaki diğer bireylere kıyasla ekonomik ve sosyal olarak dezavantajlı durumda olduğunu göstermektedir. Yoksulluğun ölçülmesinde görelî yoksulluk sınırı yaklaşımının etkinliğini değerlendirirken, yoksulluk deneyimine katkıda bulunan çeşitli faktörleri daha derinlemesine incelemek önemlidir. Gelir eşitsizliği önemli bir unsur olmakla birlikte, temel hizmetlere erişim ve hayat pahalılığı da bireylerin ve ailelerin refahının belirlenmesinde önemli rol oynamaktadır.

### **1.2.3. Öznel (Subjektif) Yoksulluk**

Öznel yoksulluk sınırı, yoksulluğu yaşayan topluluklardan ve bireylerden doğrudan bilgi toplamak için genellikle anketleri ve görüşmeleri içermektedir. Subjektif yoksulluk, bireylerin kendi durumlarını nasıl algıladıklarına dayanır, bu nedenle tamamen kişisel ve öznel bir ölçüttür. Bireylerin yoksulluk algıları, içinde buldukları kültürel, sosyal ve ekonomik bağlama göre değişebilmektedir. Aynı gelir seviyesine sahip iki kişi, farklı kültürel veya sosyal ortamlarda farklı yoksulluk algılarına sahip olabilmektedir. Bireylerin yaşam memnuniyeti, ekonomik güvenlik hissi ve geleceğe dair beklentileri, subjektif yoksulluk algısını etkileyebilir. Politika yapıcılar, bu kişilerin bakış açılarını anlayarak, öznel yoksulluk sınırının altında yaşayanların özel ihtiyaçlarına ve karşılaştıkları zorluklara yönelik çözümler üretebilmektedir.

### **1.2.4. İnsani Yoksulluk**

İnsani yoksulluk, doğal afetlerden, çatışmalardan veya diğer insani krizlerden etkilenen bireylerin ve toplulukların karşılaştığı koşulları ve zorlukları kapsayan farklı

bir yoksulluk türüdür (Bigsten & Shimeles, 2008). İnsani yoksulluğun azaltılmasına yönelik çeşitli yaklaşımlar arasında acil yardım sağlamak, altyapıyı yeniden inşa etmek ve gıda, su ve sağlık hizmetleri gibi temel ihtiyaçlara erişim sağlamak gibi doğrudan önlemler yer almaktadır. Bu doğrudan önlemler yalnızca etkilenenlerin acil ihtiyaçlarını karşılamakla kalmamakta, aynı zamanda sürdürülebilir kalkınma için dayanıklılıklarını ve kapasitelerini geri kazandırmayı da amaçlamaktadır. Ayrıca, insani yoksulluğun ele alınması, dayanıklılık oluşturmaya ve toplulukların gelecekteki krizlere karşı kırılganlığını azaltmaya odaklanan uzun vadeli sürdürülebilir çözümler de gerektirmektedir. İnsani yoksulluk, altında yatan nedenleri ve etkileri ele almak için kapsamlı bir yaklaşım gerektiren çok yönlü bir konudur.

Belirli sosyal verilerin ortaya konulmasıyla ilgili olarak, nesnel (objektif) ve öznel (sübjektif) yoksulluk arasında süregelen bir tartışma olmuştur. Ancak objektif yaklaşımın temelleri 19. yüzyıldaki sosyal istatistik geleneğine, sübjektif yaklaşımın temelleri ise 1960 yılında hanehalkları üzerinde yapılan anket çalışmalarına dayanmaktadır (Kaya, 2011: 67). Bununla birlikte objektif yoksulluk yaklaşımı belirli bir zamandaki gelir, tüketim harcamaları ve kalori miktarı gibi somut kriterlere odaklanırken; sübjektif yaklaşımda, asgari temel ihtiyaçların karşılanıp karşılanamayacağı konusunda yoksulların algısı ön plana çıkmaktadır (Şenses, 2017).

### **1.2.5. Gelir Yoksulluğu**

Yoksulluk türlerinden biri olan gelir yoksulluğu, doğrudan ve dolaylı önlemlerin bir kombinasyonu yoluyla etkili bir şekilde ele alınabilir (Manshor vd., 2020). Gelir yoksulluğu, bireylerin veya hanelerin belirli bir gelir düzeyinin altında kalarak, temel ihtiyaçlarını karşılayamaması durumu olarak tanımlanmaktadır. Bu temel ihtiyaçlar arasında yiyecek, barınma, giyim, sağlık hizmetleri ve eğitim gibi zorunlu harcamalar yer almaktadır. Gelir yoksulluğunun ele alınması hem kısa vadeli hem de uzun vadeli çözümleri birleştiren kapsamlı bir yaklaşım gerektirmektedir. Gelir desteği ve istihdam fırsatları gibi doğrudan yardım sağlamanın yanı sıra, gelir yoksulluğuna katkıda bulunan altta yatan faktörleri ele alan dolaylı önlemlerin uygulanmasına

odaklanmak çok önemlidir. Bu, eğitim ve sağlık hizmetlerine erişimi iyileştirmeyi amaçlayan girişimlerin yanı sıra girişimcilik ve ekonomik büyüme için elverişli bir ortam yaratan politikaları teşvik etmeyi de içerebilmektedir.

#### **1.2.6. Kırsal ve Kentsel Yoksulluk**

Kırsal ve kentsel yoksulluk, toplumda var olan iki yoksulluk türüdür (Bigsten & Shimeles, 2008). Kırsal yoksulluk, kırsal alanlarda veya tarımsal topluluklarda yaşayan bireylerin ve ailelerin yaşadığı yoksulluk durumunu ifade eder. Bu alanlar genellikle kaynaklara, altyapıya ve eğitim ve sağlık gibi hizmetlere sınırlı erişim ile karakterize edilir. Öte yandan kentsel yoksulluk, kentsel veya metropol alanlarda ikamet eden bireyler arasındaki yoksulluk durumuyla ilgilidir. Kentsel yoksulluk genellikle yüksek hayat pahalılığı, yetersiz barınma ve sınırlı istihdam olanakları gibi zorluklarla ilişkilendirilir. Ayrıca, kentsel alanlarda aşırı kalabalık, kirlilik ve yeşil alanlara sınırlı erişim gibi sorunlar da yaşanabilir. Özelliklerindeki farklılıklara rağmen hem kırsal hem de kentsel yoksulluk, kaliteli eğitim, sağlık hizmetleri ve diğer temel hizmetlere sınırlı erişim gibi ortak zorlukları paylaşmaktadır. Kırsal ve kentsel yoksulluğun farklı zorluklarını ve özelliklerini anlamak, her bir toplum türünün özel ihtiyaçlarına hitap eden hedefli ve etkili yoksullukla mücadele stratejileri geliştirmek için önemli olmaktadır. Politika yapımcılar ve kuruluşlar, bu farklı ortamlardaki bireylerin karşılaştığı benzersiz koşulları tanıyarak, sürdürülebilir ekonomik kalkınmayı teşvik etmek ve yoksulluktan etkilenenlerin genel refahını iyileştirmek için müdahaleleri uyarlayabilmektedirler.

#### **1.2.7. Geçici ve Kronik Yoksulluk**

Geçici ve kronik yoksulluk, yoksulluğun genel olarak anlaşılmasına katkıda bulunan iki farklı ancak birbiriyle bağlantılı olgudur (Bigsten & Shimeles, 2008). Bireylerin ve toplumların farklı ihtiyaçlarını etkin bir şekilde ele almak için geçici ve kronik yoksulluk arasında ayırım yapmak önemlidir. Geçici yoksulluk, bireylerin veya ailelerin iş kaybı, hastalık veya doğal afetler gibi öngörülemez koşullar nedeniyle bir kıtlık veya mali sıkıntı dönemi yaşadığı bir durumu ifade etmektedir. Öte yandan,

kronik yoksulluk, genellikle nesiller arası ve derinlemesine yerleşmiş olan uzun vadeli ve kalıcı yoksunluğu ifade etmektedir. Hem geçici hem de kronik yoksulluğa katkıda bulunan faktörleri anlamak, bu sorunları ele almak için hedefe yönelik müdahaleler ve politikalar geliştirmek açısından çok önemlidir.

### **1.2.8. Çok Boyutlu Yoksulluk**

Çok boyutlu yoksulluk, yoksulluğu yalnızca gelire dayalı olarak ölçmenin ötesine geçen ve eğitim, sağlık ve yaşam standardı gibi çeşitli diğer yoksunluk boyutlarını dikkate alan bir kavramdır. Bu yaklaşım, sadece gelir eksikliğini değil, aynı zamanda temel hizmetlere ve kalkınma fırsatlarına erişim eksikliğini de göz önünde bulundurarak yoksulluğun daha kapsamlı bir şekilde anlaşılmasını sağlamaktadır. Çok boyutlu yoksulluk analizi, birden fazla boyutu bir araya getirerek en kırılgan ve marjinalleşmiş nüfusların belirlenmesine yardımcı olabilir ve bu nüfusların özel ihtiyaçlarına yönelik hedefli müdahalelere rehberlik edebilmektedir. Bakış açısının tek boyutludan çok boyutlu bir yaklaşıma doğru kayması, insanların yaşamlarında sürdürülebilir iyileşmelere yol açabilecek etkili yoksulluk azaltma stratejilerinin oluşturulması için önemlidir.

### **1.3. Yoksulluk Ölçümünde Yaklaşımlar**

Yoksulluğu etkili bir şekilde ele almak için, yoksulluğun çeşitli boyutlarını yakalayabilecek ve yoksulluğa katkıda bulunan faktörleri anlayabilecek doğru ölçümlere sahip olmak çok önemlidir (Vyas & Kumaranayake, 2006). Bu ölçümler sadece gelir seviyelerini değil, aynı zamanda eğitim, sağlık ve temiz su gibi temel hizmetlere erişimi de dikkate almalıdır (Tilak, 2010).

Yoksulluk, yalnızca düşük geliri değil, aynı zamanda temel kaynaklara ve fırsatlara sınırlı erişimi de kapsayan çok boyutlu bir sorundur (Symaco, 2013). Ayrıca, coğrafi konum, doğal afetler, çatışmalar ve refahın eşitsiz dağılımı gibi faktörlerden etkilenir. Bu faktörler yoksulluğun sürekliliğine ve karmaşıklığına katkıda bulunarak onu

çözülmesi zor bir sorun haline getirmektedir. Aynı zamanda, cinsiyet, etnik köken ve engellilik gibi faktörlere dayalı sosyal dışlanma ve ayrımcılık da yoksulluğun etkilerini daha da kötüleştirmektedir. Yoksulluğu gerçekten ele almak ve azaltmak için, bu çok boyutlu yönleri ele alan kapsamlı ve bütünsel bir yaklaşım benimsemek çok önemlidir.

Dünya Bankası yoksulluğu, insanların sadece maddi varlıkları değil, aynı zamanda eğitim, sağlık, temiz su ve sanitasyon gibi temel hizmetlere erişimi de içeren bir yaşam standardına ulaşamaması olarak tanımlamaktadır. Yoksulluğu etkili bir şekilde ele almak için öncelikli adım ölçüm seçimini doğru yapmaktır.

### **1.3.1. Yoksulluk Sınırı**

Yoksulluk sınırlarını belirlemek için bu yöntem 1960'larda Sosyal Güvenlik İdaresi'nde ekonomist olan Mollie Orshansky tarafından geliştirilmiştir (History of Poverty Thresholds, 1995). O dönemde ailelerin gelirlerinin yaklaşık üçte birini gıdaya harcadığı düşünüldüğünden, yoksulluk sınırını, asgari düzeyde yeterli bir diyetin maliyetinin üçle çarpımına dayanan bir ekonomik yoksunluk ölçüsü olarak tanımlamıştır. İlerleyen süreçte barınma, giyim ve diğer temel ihtiyaçlar gibi faktörler de yönteme dahil edilmiştir.

Yoksulluk sınırı, yoksulluğun anlaşılması ve ölçülmesinde çok önemli bir araçtır. Temel ihtiyaçları karşılamak için yeterli görülen asgari gelir veya tüketim düzeyini temsil etmektedir. Yoksulluk sınırı belirlenirken aile büyüklüğü, konum ve ekonomik koşullar gibi çeşitli faktörler dikkate alınmaktadır. Yoksulluk hesaplamasını anlamak için gelir, tüketim kalıpları ve eğitime, sağlık hizmetlerine ve konuta erişim gibi parasal olmayan göstergeler analiz edilmelidir. Yoksulluk hesaplamalarını doğru bir şekilde anlamak için, yoksulluğun hem mutlak hem de görelî ölçütlerini dikkate almak önemlidir. Mutlak yoksulluk yaşamın temel ihtiyaçlarına odaklanırken, görelî yoksulluk bir toplum içindeki gelir ve servet eşitsizliklerini incelemektedir. Bu hususlar, yoksulluğun karmaşıklığını anlamak ve yoksulluğu ele almak için etkili politikalar geliştirmek için esastır.

Zaman içinde yoksulluk sınırını hesaplama metodolojisi, yoksulluk ve belirleyicileri hakkında daha kapsamlı bir anlayışı içerecek şekilde gelişmiştir. Hesaplama artık bölgesel maliyet farklılıklarını, farklı büyüklükteki haneler için ölçek ekonomilerini ve gıda dışı harcamaları dikkate almaktadır. Bu, belirli bir nüfus içindeki yoksulluk seviyelerinin daha incelikli ve doğru bir şekilde değerlendirilmesine yol açmıştır.

### **1.3.2. Hanehalkı Kullanılabilir (Harcanabilir) Fert Geliri**

Hanehalkı kullanılabilir geliri, temel ihtiyaçlar ve yaşam kalitesi için mevcut para miktarını yansıttığı için genellikle yoksulluğun bir ölçüsü olarak kullanılır (Mayan & Nor, 2020). Son çalışmalara göre, hanehalkı kullanılabilir geliri yoksulluk sınırını belirlemek için sıklıkla kullanılan bir ölçüdür. Vergiler ve diğer harcamalar hesaba katıldıktan sonra bir hanenin sahip olduğu kaynakların daha net bir resmini sunmaktadır. Birçok ülkede, hanehalkı harcanabilir gelir düzeyi, yoksulluk sınırlarını ve sosyal yardım programlarına uygunluğu belirlemek için kullanılmaktadır. Bu yaklaşım, farklı hane büyüklükleri ve bileşimlerinin değişen ihtiyaç ve harcamalarını dikkate almaktadır. Hükümetler ve kuruluşlar bu ölçütü hanelerin ekonomik refahını değerlendirmek ve yoksulluğu azaltmaya yönelik hedefli müdahaleler tasarlamak için kullanmaktadır.

Yoksulluk sınırı olarak hanehalkı harcanabilir gelirine bakarken; yaşam maliyeti, barınma, sağlık ve eğitim gibi çeşitli faktörleri göz önünde bulundurmak önemlidir. Ayrıca, bölgesel farklılıklar ve farklı aile yapılarının dikkate alınması, belirli bir toplumdaki yoksulluk seviyelerinin daha doğru bir şekilde temsil edilmesini sağlayabilmektedir.

### **1.3.3. Eşdeğerlik Ölçeği Yaklaşımı**

Hanehalkı gelirini ve bunun aile yapıları üzerindeki etkisini tam olarak anlamak için eşdeğerlik ölçeği kavramını dikkate almak önemlidir (Lusardi vd., 2001). Eşdeğerlik ölçeği, farklı özelliklere sahip haneler arasında gelirlerin ve yaşam standartlarının daha doğru bir şekilde karşılaştırılmasına olanak tanımaktadır. Bu ölçek aile büyüklüğü,

kompozisyonu ve ihtiyaçları gibi faktörleri dikkate alır ve hanelerin nominal gelirlerini buna göre ayarlamaktadır. Denklik ölçekleri, politika yapıcıların ve araştırmacıların farklı hanelerin ekonomik refahını doğru bir şekilde değerlendirmeleri için çok önemlidir. Eşdeğerlik ölçeği, farklı bileşimlere sahip hanelerin değişen ihtiyaç ve harcamalarını hesaba katarak, gelir ve yaşam standartlarının daha anlamlı bir şekilde karşılaştırılmasını sağlar. Bu, özellikle sosyal politikaların etkinliğini değerlendirirken ve farklı hane türlerinin ihtiyaç duyabileceği destek düzeyini belirlerken önemlidir. Eşdeğerlik ölçekleri, aile büyüklüğü, kompozisyonu ve ihtiyaçları gibi faktörleri göz önünde bulundurarak, farklı özelliklere sahip haneler arasındaki yaşam standartlarının daha doğru bir şekilde karşılaştırılmasını sağlamaktadır.

#### **1.3.4. Asgari Kalori Alımı Yaklaşımı**

Asgari kalori alımı yaklaşımı, yeterli ve besleyici bir diyetle erişimin genel refah için gerekli olduğunu kabul ederek yoksulluk ve gıda güvensizliğinin daha bütüncül bir şekilde anlaşılmasını sağlamaktadır. Bu yaklaşım, insanların temel beslenme ihtiyaçlarını karşılayacak minimum kalori miktarını belirlemek ve bu miktarın altında kalan bireylerin yoksul olarak kabul edilmesi esas alınmaktadır. Ayrıca, gıda güvensizliğini kökünden ele almak için çok önemli olan uygun fiyatlı ve besleyici gıda seçeneklerine yetersiz erişim gibi yoksulluğa katkıda bulunan yapısal sorunlara da ışık tutmaktadır. Açlık ve yetersiz beslenmeyle mücadele için kamu politikalarının ve kaynak tahsisinin şekillendirilmesinde kritik bir araç olarak hizmet eder ve nihayetinde genel toplumsal kalkınma ve refaha katkıda bulunmaktadır. Aynı zamanda, asgari kalori alımı yaklaşımının yoksulluğun azaltılmasının ötesinde halk sağlığı stratejileri için de etkileri vardır. Bu yaklaşım, besleyici bir diyetin önemini vurgulayarak obezite, yetersiz beslenme ve diyetle ilgili diğer sağlık sorunlarıyla mücadele çabalarını desteklemektedir. Sadece yeterli kalori tüketmenin değil, aynı zamanda genel sağlık ve refahı desteklemek için doğru besin dengesini tüketmenin önemini altını çizmektedir.

### **1.3.5. Gıda Oranı Yaklaşımı**

Gıda Oranı Yaklaşımı, yoksulluğun temel bir göstergesi olarak hanehalkının gıda tüketimine yönelik harcamalarını değerlendirmeye odaklanan bir metodolojidir (Muderedzi vd., 2019). Bu yaklaşım, hane gelirinin ne kadarının gıdaya harcılandığını inceleyerek, bir hanenin gıda harcamalarının yeterli beslenme için uluslararası kabul görmüş standartları karşılayıp karşılamadığını belirlemeyi amaçlamaktadır. Ayrıca bu yaklaşım, bir hanenin belirli bir coğrafi konumunda gıdanın erişilebilirliğini ve satın alınabilirliğini de araştırmaktadır. Gıda fiyatları, pazarlara erişim ve hanehalkının çeşitli besleyici gıdaları elde etme kabiliyeti gibi faktörleri göz önünde bulundurulmaktadır.

### **1.3.6. Temel İhtiyaçlar Maliyeti Metodu**

Temel İhtiyaçların Maliyeti Yöntemi, yoksulluğu ölçmek için sadece geliri değil aynı zamanda hanehalkı servetini ve kamu tüketimini de hesaba katarak ekonomik refah ve yoksulluğun daha incelikli bir şekilde anlaşılmasını sağlamaktadır. Farklı hanelerin değişen ihtiyaç ve harcamalarını dikkate alarak yoksulluk ve ekonomik güvenliğin daha doğru bir tasvirini sunmaktadır. Hanehalkı servetini de hesaba katan bu yöntem, gelir düzeyinin ötesinde finansal istikrar ve güvenliğin önemini kabul etmektedir.

### **1.3.7. Gıda Enerjisi Alımı Metodu**

Gıda Enerjisi Alım Yöntemi, yoksulluğu ölçmek ve bireylerin ve toplulukların beslenme durumunu değerlendirmek için yaygın olarak kullanılan bir yaklaşımdır (Muderedzi vd., 2019). Bu yöntem, porsiyon boyutları, pişirme yöntemleri ve gıda bileşimi gibi faktörleri dikkate alarak, bireylerin bildirdikleri gıda alımına dayalı olarak tükettikleri enerji (kalori) miktarının tahmin edilmesini içerir (McNutt ve ark., 2008). Yetersiz gıda alımı ve beslenme yetersizliği riski altında olabilecek bireylerin veya nüfusların belirlenmesinde değerli bir araçtır. Gıda Enerji Alımı Yönteminin en önemli avantajlarından biri, bireylerin ve toplulukların beslenme durumunun ayrıntılı bir şekilde anlaşılmasını sağlamasıdır. Enerji alımını ve gıda tüketim kalıplarını analiz

ederek, belirli diyet boşluklarının ve eksikliklerinin belirlenmesine olanak tanır. Bu bilgi, gıda güvensizliği ve yetersiz beslenmeyi ele almak üzere hedefe yönelik müdahaleler ve politikalar tasarlamak için çok önemlidir. Ayrıca, Gıda Enerjisi Alım Yöntemi, zaman içinde gıda tüketim kalıplarındaki değişiklikleri izlemek için kullanılabilir ve beslenme programlarının ve politikalarının etkinliği hakkında değerli bilgiler sağlar. Ayrıca ekonomik ve sosyal müdahalelerin gıdaya erişim ve beslenme çeşitliliği üzerindeki etkisini değerlendirmek için de bir temel oluşturmaktadır. Bu yaklaşım, farklı demografik gruplar arasında gıdaya erişim ve tüketim kalıplarındaki eşitsizlikleri ortaya çıkarmaktadır. Bu bilgiler, hassas nüfusların özel ihtiyaçlarının anlaşılması ve müdahalelerin bu nüfusların kendine özgü zorluklarını ele alacak şekilde uyarlanması açısından çok önemlidir.

### **1.3.8. Günlük Dolar Bazlı Yoksulluk Sınırı**

Günlük dolar bazlı yoksulluk sınırı, farklı ülkelerdeki yoksulluk seviyelerini ölçmek ve anlamak için önemli bir araçtır (Gutiérrez-Romero & Ahamed, 2021). Yoksulluğa düşme riskini belirlemek için hanehalkı zenginliği, kamu tüketimi ve kırılganlık gibi faktörleri dikkate almaktadır (Wolff, 2003). Bu ölçü, yoksulluk konusunda sadece gelir seviyelerine bakmanın ötesine geçen kapsamlı bir bakış açısı sunmaktadır. Günlük dolar bazlı yoksulluk sınırı, ortak bir standart temelinde karşılaştırma yapılmasına olanak tanıdığı için farklı ülkelerdeki yoksulluğun değerlendirilmesinde özellikle yararlıdır. Sadece geliri değil aynı zamanda hanehalkı refahını ve kırılganlığı da dikkate alan bu ölçü, yoksulluğa daha bütüncül bir bakış açısı sunmaktadır. Ayrıca, günlük dolar bazlı yoksulluk sınırı, ülkeler arasındaki yoksulluk seviyelerinin karşılaştırılmasına, farklılıkların vurgulanmasına ve yoksulluk içinde yaşayan bireylerin karşılaştığı ortak zorlukların belirlenmesine olanak tanımaktadır. Bu farklılıkların anlaşılması, hedefe yönelik ve etkili yoksullukla mücadele stratejilerinin geliştirilmesi için elzemdir. Hükümetler ve yardım kuruluşları bu bilgileri kaynak tahsis etmek ve müdahaleleri her ülkenin özel ihtiyaç ve koşullarına göre uyarlamak için kullanmaktadır. Buna ek olarak, hanehalkı refahı ve kırılganlığını göz önünde

bulunduran bu ölçüm, yoksulluğun temel nedenlerine ilişkin içgörüler sunmakta ve sürdürülebilir çözümlerin tasarlanmasına yardımcı olmaktadır. Kısa vadeli yardımdan uzun vadeli kalkınmaya geçişi teşvik ederek, dayanıklılık oluşturmayı ve yoksulluk döngüsünü kırmak için bireyleri ve toplulukları güçlendirmeyi amaçlamaktadır.

### **1.3.9. Ravallion Metodu: En Alt En Üst Yoksulluk Sınırı**

Ravallion Yöntemi, yoksulluğu ölçmek için yaygın olarak kullanılan bir yaklaşımdır ve özellikle en düşük üst yoksulluk sınırına odaklanmaktadır (Concialdi, 2018). Ravallion Yönteminin uygulanması, belirli bir ülke veya bölge için en düşük üst yoksulluk sınırının belirlenmesini ve hesaplanmasını içermektedir. Bu yoksulluk sınırı, temel ihtiyaçları karşılamak için gereken asgari gelir veya tüketim seviyesini temsil eder ve genellikle mutlak yoksulluk sınırından marjinal olarak daha yüksek bir seviyede belirlenir. En düşük üst yoksulluk sınırı belirlendikten sonra yöntem, bu eşiğin altında yaşayan nüfus oranını tahmin etmek için anket verilerini ve istatistiksel araçları kullanmaktadır. Ravallion Yönteminin uygulanmasındaki bir sonraki adım, yoksulluğun temel nedenlerinin analiz edilmesini ve yapısal eşitsizliklerin ve ekonomik hareketliliğin önündeki engellerin ele alınmasına yönelik stratejilerin formüle edilmesini içerir. Titiz ölçümleri kapsamlı analizlerle birleştiren bu yöntem, yoksulluğu anlamak ve yoksullukla mücadele etmek için bütüncül bir çerçeve sunmaktadır. Ayrıca Ravallion Yöntemi, politika yapıcıların ve araştırmacıların zaman içinde yoksulluktaki değişiklikleri izlemelerine ve yoksullukla mücadele müdahalelerinin etkinliğini değerlendirmelerine olanak tanımaktadır.

### **1.4. Yoksulluk Ölçümünde Endeksler**

Enerji, Yoksulluk, toplumsal ve ekonomik kalkınmanın önündeki en büyük engellerden biridir ve bu olgunun ölçülmesi, etkin politikaların geliştirilmesi için kritik bir gerekliliktir. Yoksulluğun sadece gelir düzeyine dayalı bir kavram olarak değerlendirilmesi, bu karmaşık sorunun tam anlamıyla anlaşılmasını engellemektedir.

Bu nedenle, yoksulluğun çok boyutlu doğasını dikkate alan çeşitli endeksler geliştirilmiştir (Sen, 1999). Bu endeksler, yalnızca gelir değil, aynı zamanda sağlık, eğitim, yaşam standardı gibi farklı boyutları da içermektedir.

#### **1.4.1. Kafa Sayısı Endeksi**

Kafa Sayısı Endeksi, bir nüfus içindeki yoksulluğun boyutunu değerlendirmek için ekonomide yaygın olarak kullanılan bir ölçüdür (Alkire & Foster, 2011). Yoksulluk çizgisinin altında yaşayan nüfusun toplam nüfusa oranını belirlemektedir. Bu endeksin hesaplanması oldukça basittir ve yaygın olarak kullanılmaktadır. Genellikle hükümet veya uluslararası kuruluşlar tarafından belirlenen belirli bir yoksulluk sınırının altında kalan bireylerin veya hanelerin yüzdesine dayanmaktadır (Atkinson, 1987). Kafa Sayısı Endeksinin en önemli avantajlarından biri basitliği ile yoksulluğun net ve kolay anlaşılır bir ölçüsünü sunabilmesidir. Ancak, sadece yoksul bireylerin sayısını dikkate aldığı için yoksulların ne kadar yoksul olduklarını veya yoksulluğun derinliğini hesaba katmadığını belirtmek önemlidir.

#### **1.4.2. Yoksulluk Açığı**

Yoksulluk açığı endeksi, yoksulluk oranının hesaplanmasında kullanılan temel kriterlerden biridir (Atkinson, 1987). Yoksulluk açığı endeksi, yoksul hanelerin yoksulluk çizgisine ulaşmak için ne kadar ek gelire ihtiyaç duyduklarını ölçmektedir. Bu endeks, yoksulların ne kadar yoksul olduğunu ve yoksulluğun derinliğini göstermektedir. Sadece yoksulluk sınırının altında yaşayan nüfusun oranını değil, aynı zamanda yoksulluk sınırının ne kadar altına düştüklerini de dikkate alarak yoksulluğun derinliğini ölçmektedir. Yoksulluk açığı endeksi, bir nüfus içindeki yoksulluğun ciddiyetini anlamak için önemli bir araçtır. Yoksulluklarının derinliğini hesaba katarak yoksulluk sınırının altında yaşayan insanların yüzdesinden daha incelikli bir bakış açısı sağlamaktadır. Bu endeks, yoksulluk sınırının altında yaşayan bireylerin veya ailelerin gelir veya tüketim açığını dikkate alarak genel yoksulluk durumunun daha kapsamlı bir şekilde değerlendirilmesine olanak tanımaktadır. Yoksulluk açığı endeksi, yoksulluğun yoğunluğuna dair daha net bir resim sunmakta ve şiddetli

yoksulluk vakalarını ele alan müdahalelere ve politikalara öncelik vermek için kullanılabilir. Ancak, bu endeks büyük ölçüde gelir verilerine dayanmaktadır; bu veriler kayıt dışı ekonomileri ve yoksulluğun parasal olmayan biçimlerini hesaba katmamaktadır. Gelir eşitsizliklerine bu dar odaklanma, ötekileştirilmiş nüfusların yaşadığı günlük mücadeleleri ve yoksulluğun finansal olmayan yönlerini gözden kaçırabilmektedir. Bu nedenle, Yoksulluk açığı endeksi gelirle bağlantılı yoksulluk hakkında değerli bilgiler sunarken, yoksulluğun ve yoksulluğun toplum üzerindeki etkilerinin kapsamlı bir şekilde anlaşılması için bu ölçütün daha geniş sosyo-ekonomik faktörler ve niteliksel göstergelerle tamamlanması büyük önem taşımaktadır.

#### **1.4.3. Atkinson Endeksi**

Atkinson Yoksulluk Endeksi, bir nüfus içindeki gelir dağılımını dikkate alan bir ekonomik eşitsizlik ölçüsüdür. Adını İngiliz ekonomist Anthony Barnes Atkinson'dan almış olup bir toplumdaki yoksulluğun boyutunu değerlendirmek için kullanılmaktadır. Endeks, bir nüfusun ortalama geliri alınarak ve daha sonra buna bir eşitsizlikten kaçınma ölçüsü uygulanarak hesaplanmaktadır. Bu eşitsizlikten kaçınma ölçüsü, gelir dağılımındaki eşitsizliğe karşı duyarlılık derecesini belirleyen Atkinson parametresi ile temsil edilmektedir. Endeks, eşitsizliğin genel refah üzerindeki etkisini ölçmek için bir yol sunmakta ve belirli bir nüfus içindeki gelir dağılımı ve yoksulluk seviyeleri hakkında fikir vermektedir. Atkinson Endeksinin sınırlamalarından biri, yalnızca gelire odaklanarak servet veya varlık dağılımını dikkate almamasıdır. Bu, bir nüfus içindeki genel ekonomik eşitsizliğin kapsamlı bir şekilde anlaşılabilirliği anlamına gelmektedir. Buna ek olarak, Atkinson Endeksi bireylerin benzer tercihlere sahip olduğunu varsaymakta ve bu gerçekte geçerli olmayabilmektedir.

#### **1.4.4. Sen Endeksi**

Sen Endeksi Nobel ödüllü Amartya Sen tarafından geliştirilmiştir ve farklı ülke ve bölgelerdeki yoksulluğu değerlendirmek için yaygın olarak kullanılmaktadır. Bu

endeks gelir, tüketim ve varlık sahipliği gibi farklı göstergeleri bir araya getirerek yoksulluğun daha kapsamlı ve bütüncül bir şekilde anlaşılmasını sağlamaktadır (Vyas & Kumaranayake, 2006). Sen endeksi, yoksulluk ve gelir eşitsizliğini bir arada değerlendirmektedir. Bu endeks, kafa sayısı yoksulluk oranı ve yoksulluk açığını dikkate almakta ve aynı zamanda yoksul bireyler arasındaki gelir dağılımını da içermektedir. Aynı zamanda, bir nüfus içindeki eşitsizlikleri ortaya çıkarabilirken, marjinal grupları vurgulayabilir ve eşitsizliği azaltmaya yönelik hedeflenen çabaları bilgilendirebilir. Çok boyutlu yaklaşımı, yoksulluğu azaltmayı amaçlayan etkili politika ve programların tasarlanması için çok önemli olan yoksulluğun daha incelikli bir şekilde anlaşılmasını sağlamaktadır. Sen Endeksi'nin temel dezavantajlarından biri karmaşıklığı ve hesaplama sürecidir. Özellikle kayıt dışı ekonomilerin yaygın olduğu gelişmekte olan ülkelerde elde edilmesi zor olabilen bireysel gelirlere ilişkin veri gerektirmektedir. Ayrıca Sen Endeksi, yoksulluk ve eşitsizliğin önemli yönleri olan ayrımcılık, sosyal dışlanma veya güç dinamikleri gibi sosyal faktörleri dikkate almamaktadır. Bu da yoksulluğa dar bir perspektiften bakılmasına ve yoksulluğu sürekli kılan temel nedenlerin ve sistemik sorunların ele alınmamasına yol açabilmektedir.

#### **1.4.5. Watts Endeksi**

Watts endeksi, yoksulluk içinde yaşayanları yakından ilgilendiren ekonomik, sosyal ve siyasi bağlamlara ilişkin içgörü sağlayan bir yoksulluk ölçütüdür (Manshor vd., 2020). Endeks ilk olarak sosyolog Paul Watts tarafından, yoksulluğun sadece gelir seviyelerinin ötesinde kapsamlı bir şekilde anlaşılmasını sağlamak amacıyla geliştirilmiştir. Watts Endeksi, bireylerin gelir düzeyleri arasındaki logaritmik farklılıklara dayanmaktadır. Bu endeks, gelir dağılımındaki eşitsizlikleri logaritmik gelir farklarına dayanarak değerlendirmekte ve eşitsizlik ölçüsü olarak kullanılmaktadır. Watts endeksi; gelir düzeyleri, eğitime, sağlık hizmetlerine ve temel olanaklara erişimin yanı sıra işsizlik oranları gibi çeşitli faktörleri de dikkate almaktadır. Politika yapıcılar ve araştırmacılar bu unsurları analiz ederek bir topluluk veya bölgedeki yoksulluğun kapsamı ve derinliği hakkında bir anlayış

kazanabilmektedir. Ayrıca zaman içinde yoksulluk seviyelerindeki değişiklikleri izlemek için de kullanılabilir ve yoksulluğu azaltma stratejilerinin ve politikalarının etkinliğinin değerlendirilmesine olanak tanımaktadır. Watts Endeksi yoksulluk ölçümünde kullanılan yoksulluk ölçütlerinden biridir, ancak dezavantajları da yok değildir (Atkinson, 1987). Watts Endeksinin en büyük dezavantajlarından biri, hane içindeki gelir dağılımındaki farklılıkları dikkate almamasıdır. Bu, özellikle hanehalkı üyeleri arasında gelir düzeylerinde önemli bir eşitsizlik olduğu durumlarda, bir hanenin tüm üyeleri için yaşam standardını doğru bir şekilde yansıtmayabileceği anlamına gelmektedir.

#### **1.4.6. Kakwani Endeksi**

Kakwani Endeksi, belirli bir nüfustaki yoksulluk ve eşitsizlik düzeyini değerlendirmek için kullanılan istatistiksel bir ölçüttür (Kakwani, 1993). Kakwani Endeksi, Gini katsayısına dayanarak hesaplanır ve vergi sistemlerinin ilerici veya gerici olup olmadığını belirlemede nicel bir ölçüm olarak kullanılmaktadır. Gelir dağılımını dikkate alarak, yoksulluğun orantısız bir şekilde toplumun daha yoksul kesimleri arasında ne ölçüde yoğunlaştığını ölçmektedir. Ayrıca, Kakwani Endeksi farklı nüfusları veya bölgeleri karşılaştırmada yararlı olup yoksulluk ve eşitsizliğin ülkeler arası veya bölgeler arası analizlerine olanak tanımaktadır.

#### **1.4.7. Sen, Shorracks, Thon Endeksi**

Sen, Shorracks, Thon Endeksi, Amartya Sen tarafından ekonomistler Shubham Shroff ve Anirban Thon ile birlikte geliştirilen ve yaygın olarak kullanılan bir ölçüm yöntemidir. SST Endeksi, refah ve yaşam standardının daha kapsamlı bir ölçüsünü sağlamak için gelir, eğitim ve sağlık gibi çeşitli göstergeleri dikkate alan bileşik bir endekstir. SST Endeksi, kalkınmanın birçok boyutunu bir araya getirerek, gayrisafi yurtiçi hasıla gibi geleneksel ekonomik ölçütlere kıyasla insanların yaşam kalitesine ilişkin daha incelikli bir anlayış sunmaktadır. Bu endeks yoksulluğu ölçmek için kullanılan bir bileşik endekstir. SST Endeksi, yoksulluk oranını, yoksulluk açığını ve yoksullar arasındaki gelir dağılımındaki eşitsizliği dikkate almaktadır. Bu endeks,

daha kapsamlı bir yoksulluk ölçütü sunarak, sadece yoksul bireylerin sayısını değil, aynı zamanda yoksulluğun derinliğini ve yoksullar arasındaki eşitsizliği de değerlendirmektedir. Son yıllarda SST Endeksi, Birleşmiş Milletler tarafından belirlenen Sürdürülebilir Kalkınma Hedeflerine yönelik ilerlemenin değerlendirilmesinde önemli bir araç olarak ilgi görmeye başlamıştır. Ancak SST endeksi, hayat pahalılığındaki bölgesel farklılıkları dikkate almamakta ve bu da farklı bölgelerdeki yoksulluk seviyelerinin yanlış temsil edilmesine neden olabilmektedir. Ayrıca endeks, eğitim, sağlık ve diğer temel hizmetlere erişim gibi yoksulluğun parasal olmayan yönlerini de dikkate almamaktadır

#### **1.4.8. Takayama Endeksi**

Takayama Endeksi, belirli bir nüfus içindeki yoksulluk seviyelerinin ölçülmesinde kullanılan yaygın olarak tanınan bir araçtır. Yoksulluğun kapsamlı bir değerlendirmesini sağlamak için gelir, yaşam standartları ve temel ihtiyaçlara erişim gibi faktörleri dikkate alır (Atkinson, 1987). Takayama Endeksi, gelir dağılımındaki eşitsizliği ölçmek için kullanılan bir endeks olup, doğrudan bir yoksulluk ölçütü olmayıp; gelir dağılımındaki eşitsizliklerin yoksulluğu etkileyebileceği düşünülerek dolaylı olarak yoksulluk analizi için kullanılabilir. Daha yüksek Takayama Endeksi değerleri, gelir dağılımında daha büyük eşitsizlik olduğunu ve dolayısıyla bazı grupların yoksulluk içinde olma olasılığının daha yüksek olduğunu göstermektedir.

#### **1.4.9. Theil, Bourguignon Endeksi**

Theil-Bourguignon yoksulluk endeksi, yoksulluğun kapsamlı bir şekilde anlaşılmasını sağlamak için yoksulluk oranı ve gelir eşitsizliği kavramlarını birleştiren bir ölçüdür (Atkinson, 1987). Belirli bir gelir eşliğinin altında yaşayan bireylerin oranını ve bunlar arasındaki gelir dağılımındaki eşitsizlikleri dikkate almaktadır. Bu endeks sadece yoksulluğun boyutunu değil, aynı zamanda bir toplum içindeki eşitsizliğin derecesini de yakalamaya yardımcı olmaktadır. Endeks özünde, belirli bir gelir eşliğinin altında yaşayan insanların oranını dikkate alarak bir nüfus içindeki yoksulluğun yaygınlığına

değınmektedir. Bu endeksin temel dezavantajlarından biri, seçilen birime bağılı olarak farklı yoksulluk tahminlerine yol açabilen gelir birimi seçimine olan duyarlılığıdır.

#### **1.4.10. Çok Boyutlu Yoksulluk Endeksi**

Çok Boyutlu Yoksulluk Endeksi, yoksulluğun daha kapsamlı bir şekilde anlaşılmasını sağlamak için geleneksel gelire dayalı yoksulluk ölçümlerinin ötesine geçen bir ölçümdür (Atkinson, 1987). Yoksulluğa daha bütüncül bir bakış açısı sağlamak için eğitim, sağlık ve yaşam standartları gibi çeşitli faktörleri dikkate almaktadır. Bu endeks yoksulluğu sadece gelire değil, sağlık, eğitim ve yaşam standartları gibi birden fazla boyutla ölçmektedir. Her bir boyut için belirli göstergeler kullanılır ve toplam yoksulluk bu boyutların ağırlıklı ortalamasıyla hesaplanmaktadır. Çok Boyutlu Yoksulluk Endeksi, bu farklı boyutları bir araya getirerek, yoksulluk içinde yaşayan bireylerin ve toplulukların karşılaştıkları zorluklara ilişkin daha incelikli bir anlayış sunmaktadır.

#### **1.4.11. Eşitsizliğe Uyarlanmış İnsani Gelişme Endeksi**

Eşitsizliğe Uyarlanmış İnsani Gelişme Endeksi, bir toplumdaki kaynakların ve fırsatların dağılımını dikkate alarak geleneksel insani gelişme ölçütlerinin ötesine geçmeyi amaçlayan bir ölçüttür (Anand & Sen, 1994). Eşitsizliğe Uyarlanmış İnsani Gelişme Endeksi, yalnızca genel sağlık, eğitim ve yaşam standardı seviyelerini değil, aynı zamanda bu faydaların bir nüfus içindeki dağılımını da dikkate alarak insani gelişmenin daha kapsamlı bir şekilde anlaşılmasını sağlamaktadır. Bu sayede endeks, eşitsizliğin bir ülkedeki insani kalkınmayı ne ölçüde etkilediğini ortaya koymaktadır.

### **1.5. Türkiye'deki Mevcut Yoksulluk Durumu ve Göstergeleri**

Yoksulluk, toplumsal refahın ve ekonomik kalkınmanın önemli göstergelerinden biridir. Aynı zamanda yoksulluk çok yönlü ve karmaşık bir konudur ve ölçümü Türkiye'de süregelen bir tartışma konusudur. (Buğra, 2007). Türkiye'de yoksulluk ölçümleri, Türkiye İstatistik Kurumu (TÜİK) tarafından yürütülmektedir. TÜİK, yoksulluk hesaplamalarını yıllar içinde geliştirerek, uluslararası standartlarla uyumlu

ve çok boyutlu yöntemler kullanarak gerçekleştirmiştir. 1980'lerden önce Türkiye'de yoksullukla ilgili kapsamlı bir veri toplama ve analiz sistemi bulunmamaktaydı. Yoksulluk genellikle genel ekonomik göstergeler ve makroekonomik veriler üzerinden değerlendirilirdi. Bu dönemde yoksulluk, gelir dağılımı ve işsizlik gibi temel ekonomik göstergelerle ilişkilendirilerek ele alınmaktaydı. 1990'larda Türkiye'de yoksulluk konusundaki farkındalık artmaya başlamasıyla TÜİK, daha sistematik ve kapsamlı veri toplama ve analiz yöntemleri geliştirmeye yöneldi. Bu dönemde hanehalkı bütçe anketleri gibi araştırmalarla yoksulluk verileri toplanmaya başlandı. Bu anketler, hanelerin gelir ve harcama kalıplarını inceleyerek yoksulluk ölçümleri için temel veriler sağladı. 2000'li yıllarda TÜİK, Avrupa Birliği'ne uyum süreci çerçevesinde veri toplama ve analiz yöntemlerini uluslararası standartlara uygun hale getirmiştir. Bu kapsamda 2006 yılı itibarıyla gelir dağılımı yanında, yaşam koşulları, sosyal dışlanma ve göreceli gelir yoksulluğu konularını bulundurduğu “Gelir ve Yaşam Koşulları Araştırması”nı (GYKA) uygulamaya başlamıştır (TÜİK). 2010'lu yıllarda TÜİK, yoksulluk ölçümlerinde daha kapsamlı ve çok boyutlu yaklaşımlar benimsedi. Gelir ve yaşam koşulları anketleri, hanehalkı işgücü anketleri gibi daha detaylı veri toplama yöntemleri kullanıldı. Günümüzde TÜİK, yoksulluk ölçümlerini uluslararası standartlara uygun olarak gerçekleştirmekte ve Avrupa Birliği İstatistik Ofisi (Eurostat) ile uyumlu göstergeler ve oranlar kullanmaktadır (TÜİK, 2022): Göreceli yoksulluk, yoksulluk sınırı, yoksulluk oranı, yoksulluk açığının yanı sıra; satınalma gücü paritesi (SAGP), hanehalkı kullanılabilir net geliri, eşdeğerlik ölçeği, eşdeğer hanehalkı kullanılabilir fert geliri, maddi yoksulluk oranı, maddi ve sosyal yoksulluk oranı ve son yıllarda ise yoksulluk ve sosyal dışlanma riski altında olanların oranı (AROPE) göstergesini Eurostat revizeleri sonucu üretmeye başlamıştır (TÜİK).

Yoksulluğun tanımlanması, son dönemdeki kavramsal ve ölçümsel gelişmelerin de gösterdiği üzere, dar odaklı bir gelir düzeyi değerlendirmesinin ötesine geçmiştir (Vidyasagar, 2006). Yoksulluk artık sadece maddi yoksullukları değil, aynı zamanda sosyal ve siyasi eşitsizlikleri de kapsayan çok boyutlu bir deneyim olarak kabul edilmektedir (Caplan vd., 2017). Coğrafi konum, biyolojik özellikler ve sosyal

belirleyiciler gibi faktörler, gelirin bir bireyin genel refahı üzerindeki etkisini artırabilir veya azaltabilir (Jamaluddin & Hanafiah, 2020). Yoksulluğun karmaşık ve çok yönlü doğasını kabul etmek, sosyal dışlanma sorununu ele almak için kapsamlı stratejiler geliştirmede çok önemlidir. Bu kapsamda TÜİK, sürdürülebilir kalkınma hedeflerine uygun olarak yoksulluğun azaltılması ve izlenmesi amacıyla daha geniş çaplı veri toplama ve analiz yöntemleri kullanmaktadır.

**Tablo 1.5.1. Eşdeğer Hanehalkı Kullanılabilir Fert Gelirine Göre Hesaplanan Yoksulluk Oranı (%), 2017-2023**

Anket yılı	2017	2018	2019	2020	2021	2022	2023
<b>Gelir referans yılı</b>	2016	2017	2018	2019	2020	2021	2022
<b>Medyan gelirin %40'ına göre</b>	7,4	7,9	8,3	8,9	8,5	7,6	7,4
<b>Medyan gelirin %50'ına göre</b>	13,5	13,9	14,4	15,0	14,4	14,4	13,9
<b>Medyan gelirin %60'ına göre</b>	20,1	21,2	21,3	21,9	21,3	21,6	21,7
<b>Medyan gelirin %70'ına göre</b>	28,1	28,5	28,5	29,0	28,7	29,3	29,7


Kaynak: TÜİK, 2023

- Medyan gelirin %40'ı, bir toplumda en düşük gelirli kesimin oranını temsil etmektedir. 2017 yılında %7,4 olan bu oran, 2018'de %7,9'a ve 2019'da %8,3'e yükselmiştir. 2020'de %8,9 ile zirveye ulaşan oran, sonraki yıllarda düşüş göstermiş ve 2023 yılında tekrar %7,4 seviyesine gerilemiştir.

- Medyan gelirin %50'sine göre yoksulluk oranı, 2017 yılında %13,5 iken, 2018'de %13,9'a çıkmış ve 2019'da %14,4 olmuştur. 2020 yılında %15,0 ile en yüksek seviyesine ulaşan oran, 2021'de %14,4'e gerilemiş ve 2023'te de %13,9 olarak kaydedilmiştir.
- Medyan gelirin %60'ına göre yoksulluk oranı, 2017'de %20,1 iken, 2018'de %21,2'ye çıkmış ve 2019'da %21,3 olmuştur. 2020'de %21,9 ile en yüksek seviyesine ulaşan oran, sonraki yıllarda hafif dalgalanmalar göstermiş ve 2023 yılında %21,7 olarak kaydedilmiştir.
- Medyan gelirin %70'ine göre yoksulluk oranı, 2017 yılında %28,1 iken, 2018'de %28,5'e çıkmış ve 2019'da da aynı seviyede kalmıştır. 2020 yılında %29,0 ile zirveye ulaşan oran, sonraki yıllarda artış eğilimini sürdürmüş ve 2023 yılında %29,7 olarak kaydedilmiştir.

Veriler, 2017'den 2023'e kadar geçen süre zarfında medyan gelirin %40, %50, %60 ve %70'ine göre belirlenen yoksulluk oranlarında belirgin değişiklikler olduğunu göstermektedir. Özellikle 2020 yılında tüm yoksulluk oranlarının zirveye ulaştığı görülmektedir. Bu durum, küresel COVID-19 pandemisinin ekonomik etkileriyle ilişkilendirilebilir. Sonraki yıllarda ise bir miktar iyileşme gözlemlense de medyan gelirin %60 ve %70'ine göre yoksulluk oranlarının 2023'te hala yüksek olduğu dikkat çekmektedir.

**Şekil 1.5.2. Satınalma Gücü Paritesi (SGP) Kullanılarak Hesaplanan Gelire Dayalı Görelî Yoksulluk Sınırına Göre Yoksulluk Oranı 2006-2023**



Kaynak: TÜİK, 2023

Şekil 1.5.1.'de, 2006-2023 yılları arasında Türkiye'deki görelî yoksulluk oranlarının medyan gelirin %40, %50, %60 ve %70'ine göre nasıl değiştiğini göstermektedir. Veriler, Satınalma Gücü Paritesi (SGP) kullanılarak hesaplanan gelire dayalı görelî yoksulluk sınırlarına göre TÜİK'in 2023 yılı verilerine göre oluşturulmuştur.

- Medyan Gelirin %40'ına Göre Yoksulluk Oranı

Medyan gelirin %40'ına göre hesaplanan yoksulluk oranı, 2006 yılında %12,2 iken 2023 yılında %6,6'ya kadar düşmüştür. Bu düşüş, genel olarak sürekli bir azalma eğilimi göstermektedir, özellikle 2015-2017 yılları arasında belirgin bir düşüş gözlemlenmektedir.

- Medyan Gelirin %50'sine Göre Yoksulluk Oranı

Medyan gelirin %50'sine göre yoksulluk oranı 2006 yılında %17,9 iken 2023 yılında %13,0'a düşmüştür. Bu oran da genel olarak azalma eğilimi göstermektedir, ancak bazı yıllarda (2018 ve 2019) minimal artışlar gözlemlenmiştir.

- Medyan Gelirin %60'ına Göre Yoksulluk Oranı

Medyan gelirin %60'ına göre yoksulluk oranı, 2006 yılında %24,5 iken 2023 yılında %20,9'a düşmüştür. Bu oran, diğer iki ölçüme göre daha az değişkenlik göstermektedir. Genel eğilim yine de düşüş yönündedir, ancak 2020 yılında hafif bir artış gözlemlenmiştir.

- Medyan Gelirin %70'ine Göre Yoksulluk Oranı

Medyan gelirin %70'ine göre yoksulluk oranı, 2006 yılında %32,1 iken 2023 yılında %29,4'e düşmüştür. Bu oran, diğer ölçümlere göre daha yüksek bir başlangıç seviyesine sahip olmakla birlikte, genel olarak sabit bir azalma eğilimi göstermektedir. 2018 ve 2020 yıllarında ise küçük dalgalanmalar yaşanmıştır.

2006-2023 yılları arasında, Türkiye'de medyan gelirin farklı yüzdelere göre yoksulluk oranlarında genel bir azalma eğilimi gözlemlenmektedir. Bu, ekonomik büyüme, sosyal yardımlar ve yoksullukla mücadele politikalarının etkili olduğunu gösterebilir. Özellikle 2015 yılından sonra yoksulluk oranlarında belirgin bir düşüş gözlemlenmektedir. Ancak bazı yıllarda (örneğin 2018 ve 2020) küçük dalgalanmalar ve artışlar, ekonomik krizler veya dış etkenler nedeniyle meydana geldiği düşünülmektedir. 2020 yılında pandeminin etkisiyle medyan gelirin %50 ve %60'ına göre yoksulluk oranlarında artış görülmüştür.

## İKİNCİ BÖLÜM

### LİTERATÜR TARAMASI

Yoksulluğun tahmini hem klasik hem de modern yaklaşımları inceleyen çok sayıda çalışma ile uzun süredir devam eden bir araştırma alanı olmuştur (Sugasawa vd., 2018). Zaman içinde yoksulluk anlayışı, dar bir gelir odağının ötesine geçerek daha çok boyutlu bir bakış açısını kapsayacak şekilde gelişmiştir (Zulkifli ve Abidin, 2023). Literatür taramasında yoksulluk tahmininde gerçekleştirilen klasik ve modern yöntemler incelenmiştir.

Canbay ve Selim (2010) çalışmalarında, 2004 yılına ilişkin TÜİK tarafından yapılan Hanehalkı Bütçe Anketi üzerinden logit model kullanarak kentsel ve kırsal kesimler için bir yoksulluk analizi yapmışlardır. Analizde yoksulluk üzerinde etkisi bulunan en önemli değişkenlerin; hanehalkı reisinin işteki durumu, işyerinin statüsü, işyeri faaliyeti ve kentsel kesimde hanehalkı büyüklüğünün olduğunu tespit etmişlerdir.

Değirmenci (2020) çalışmasında, 2017 yılında TÜİK tarafından yapılan Hanehalkı Gelir ve Yaşam Koşulları Anketi üzerinden derlenen verileri hanehalkı sorumlusu temelinde analiz edilerek Türkiye'de yoksulluğu etkileyen demografik faktörleri bölgesel olarak incelenmiştir. 2017 yılına ilişkin ortalama yoksulluk sınırının baz alındığı, 9 farklı değişken üzerinden analiz yapılmıştır. Yoksulluktan sorumlu demografik faktörlerin, her bölgenin sosyokültürel özelliklerine bağlı olarak bölgeler arasında farklılık gösterdiği ortaya çıkmıştır.

Topal ve Akay (2020) araştırmalarında, 2018 yılına ilişkin TÜİK tarafından yapılan Hanehalkı Bütçe Anketi üzerinden haneye ilişkin değişkenler ile hanelerin tüketim harcamalarının tahmininde klasik regresyon yöntemlerine ek olarak En Küçük Mutlak Sapma (LAD), En Küçük Mutlak Küçültme ve Seçim Operatörü (LASSO) ve LAD-

LASSO yöntemleri uygulamışlardır. Oluşturdukları tüm modellerde hanehalkı tüketim harcamalarını önemli düzeyde etkileyen değişkenler olarak gelir, tasarruf ve hanehalkı büyüklüğünü bulurken aynı zamanda odanın yapısı, müstakil ev, apartman, kredi kartı kullanımı, internet alışveriş alışkanlıkları gibi çeşitli değişkenlerin de önemli bulunduğunu tespit etmişlerdir. Ayrıca mikroekonometrik modellerin oluşturulmasında gerekli değişkenlerin seçimi için makine öğrenme algoritmalarının etkili bir şekilde kullanılabileceğini öne sürmüşlerdir.

Şentürk ve Çelik (2021) araştırmalarında, hanehalkı yoksulluğunu etkileyen faktörleri belirlemek, bunların yoksul hanelerin harcanabilir gelirleri üzerindeki etkilerinin büyüklüğünü değerlendirmek ve hanehalkı yoksulluğu üzerindeki etkilerini tahmin etmek için ANOVA analizini kullanılmışlardır. Bu çalışma, TÜİK tarafından 2016 yılına ilişkin Gelir ve Yaşam Koşulları Araştırması'ndan toplanan verilere dayanmaktadır. Çeşitli hizmetlere erişim, yaşanan konuta ilişkin temel bilgiler ve bölgesel düzey gibi çeşitli değişkenler ile gerçekleştirdikleri analizde; hanehalkı büyüklüğünün yoksulluk üzerinde önemli bir değişken olduğunu, Batı bölgelerindeki yoksul hanelere kıyasla, Doğudaki yoksul hanelerin ortalama olarak daha fazla gelirlerinin olduğunu ve tek yetiştikinin bulunduğu hanelerde yoksulluğun daha fazla olduğunu ortaya koymuşlardır.

Turna (2022) çalışmasında, tüketim harcamaları üzerinden bağımlı değişken olarak yeni bir yoksulluk açığı oranı oluşturarak bağımsız değişkenleri ise ekonomik faktörler, sosyo-ekonomik faktörler ve demografik faktörler olmak üzere gruplandırarak DVM ve YSA ile bu verileri analiz etmiştir. YSA ile kurulan ilk modelde ekonomik büyümenin, YSA ile kurulan ikinci modelde eğitim harcamaları ve beşerî sermaye indeksinin, YSA ile kurulan üçüncü modelde ise nüfus artışının yoksulluğu önemli derecede etkilediği tespit edilmiştir.

Dünya Bankası (2005) 1994-2002 dönemine ait Türkiye Hanehalkı Bütçe Anket çalışmalarını kullanarak yoksulluğu incelemiştir. Probit regresyon modelinin kullanıldığı analiz sonucuna göre eğitim, sağlık, işgücü piyasası, sosyal koruma uygulamalarının yoksulluk riskini azaltırken, makroekonomik istikrarsızlıkların yoksulluk riskini arttırmakta olduğu ortaya koyulmuştur.

Kızılgöl (2009) çalışmasında Türkiye’de hanehalkı yoksulluğunu etkileyen faktörleri incelemiştir. Çalışmada 2002-2006 yılları için TÜİK Hanehalkı Bütçe anketleri kullanılmış olup, analizler lojistik regresyon yöntemi ile gerçekleştirilmiştir. Elde edilen sonuçlara göre eğitim, yoksulluk riskini azaltıcı yönde etki ederken hanehalkı büyüklüğü ve hanelerin kırsal bölgelerde yaşaması yoksul olma riskini arttırıcı yönde etkilemektedir.

Li vd. (2022) araştırmalarında, Kırgızistan’da 2012 yılı verisi ile 8,040 hanehalkında yaşayan 35,805 bireyin yoksulluğuna ilişkin tahminleri eğitim, hanehalkı durum, yaşam kalitesi, sağlık değişkenleri ile yapmış olup, analizleri sonucu XGBoost ve Genelleştirilmiş Lineer Model (GLM) algoritmalarını karşılaştırmıştır. XGBoost algoritmasının, çoğu durumda GLM'den daha iyi performans gösterdiğini belirtmişlerdir. Çalışma veri setinin sınırlamalarını kabul ederek, ampirik sonuçları doğrulamak için daha fazla araştırmaya ihtiyaç olduğunu da eklemiştir.

Zixi (2021), yoksulluk tahmini için 4 farklı makine öğrenmesi modeli (Karar ağacı, rastgele orman, gradyan artırma, sinir ağı) ile çalışmıştır. Oxford Yoksulluk ve İnsani Gelişme Girişimi (OPHI) ile Yoksulluk Olasılık Endeksi (PPI) verilerini birlikte kullanarak, yoksulluk tahmini için en iyi algoritmanın %78 doğruluk ile gradyan artırma olduğunu belirtmiştir. Doğruluk değerlerine bakıldığında karar ağacı algoritması her ne kadar %82 olsa da aşırı öğrenmenin buna sebep olduğunu belirtmiştir.

Aulia vd. (2020) makine öğrenimi algoritmalarını kullanarak Endonezya'da e-ticaret verilerine dayalı yoksulluk oranı tahmini için bir çerçeve önermişlerdir. E-ticaret verilerindeki öğelerin ve yönlerin etkisi, yoksulluk oranı tahmini ile birlikte araştırdıkları çalışmada, e-ticaret verilerinin potansiyel olarak şehir düzeyindeki yoksulluk oranlarını hesaplamak için bir vekil olarak kullanılabileceğini göstermişlerdir. Endonezya'da yoksulluk tahmini için en önemli iki öğenin arabaya ve motosiklete sahip olmak olduğu açıklamışlardır.

Özellikle sınırlı veri durumunda karşılaşılan transfer öğrenme yöntemi ile evrişimli sinir ağlarını kullanarak sadece gece ışıklarının parlaklıklarını değil aynı zamanda gündüz ışıklarının da parlaklıklarını ele alarak Jean vd., (2016) beş Afrika ülkesi için tüketim harcamaları ve varlık zenginliklerinin tahmini için kolay ve ölçeklenebilen bir yapı önermişlerdir. Ekonomik refah için iki farklı göstergeden yararlanmışlardır: Dünya Bankası'nın Yaşam Standartları Ölçüm Anketleri aracılığıyla ölçülen tüketim harcamaları ile Demografi ve Sağlık Harcamaları Anketinden alınan hanehalkı varlık puanıdır. Bu anketlerdeki verilerin koordinatlarını 10 kilometrekareye 10 kilometrekare olmak üzere ortalama ışık parlaklıklarını hesaplayarak çalışmayı gerçekleştirmişlerdir.

Xie vd. (2016) yüksek çözünürlüklü uydu görüntülerinden büyük ölçekli sosyoekonomik göstergeleri çıkarmak için bir makine öğrenimi yaklaşımını geliştirmişlerdir. Bu yaklaşım, transfer öğrenimi kullanarak gece ışık yoğunluklarını bir öznitelik olarak kullanır ve gündüz görüntülerinden gece ışıklarını tahmin etmek için tamamen konvolüsyonel bir CNN modeli eğitmektedir. Makalede iki farklı veri seti kullanılmıştır. Birincisi, NOAA tarafından sağlanan yüksek çözünürlüklü uydu görüntüleri kullanılarak oluşturulan gece ışık yoğunluğu veri setidir. İkincisi, Uganda'da yapılan Living Standards Measurement Study (LSMS) anketi sonuçlarından oluşan yoksulluk tahmini veri setidir. Uganda'da yapılan bu çalışmada, önerilen yaklaşımın kullanılmasıyla yoksulluk seviyelerinin tahmini için saha verilerine yakın bir doğruluk elde edildiğini belirtmişlerdir. Transfer öğrenimi

yaklaşımının, diğer uzaktan algılama görevlerine kolayca uyarlanabileceğini ve küresel sürdürülebilirlik sorunlarının çözümüne yardımcı olacağı göstermişlerdir. Makale, gelişmiş ülkelerin veri bolluğu ile karşılaştırıldığında, gelişmekte olan ülkelerin veri yoksunluğu yaşadığına dikkat çekerek, veri eşitsizliği sorununa da işaret etmektedir.

Hindistan'daki yoksulluğa dair istatistiklerin beş yılda bir yayınlanmasından yola çıkan Subash vd. (2018) bu eksik yıllardaki açığı kapatmak adına yüksek frekanslı gece ışıkları verilerini yoksulluk tahmininde kullanmıştır. Veri seti Michigan Üniversitesi tarafından sağlanan açık erişimli gece lambası verisinden toplanmıştır. Bu veri seti 1993'ten 2013'e kadar kırsal gece lambası verileri sağlamaktadır. Gece yanan lambaları baz alarak kişi başına düşen milli hasıla ile karşılaştırmışlar ve yoksulluğun tahmininde gece lambası verilerinin, kişi başına düşen milli hasıladan daha iyi sonuç verdiğini bulmuşlardır.

Engstrom vd. (2019) Accra, Gana'da yoksulluk oranlarını değerlendirmek ve gecekondu bölgelerini haritalandırmak için makine öğrenimi de dahil olmak üzere birden fazla metodolojinin kullanımını ele almıştır. Makalede üç farklı veri seti kullanılmıştır: Nüfus sayımı verileri 2010 yılında Accra Metropolitan Assembly (AMA) bölgesindeki 2,402 sayım alanından, Ev halkı anket verileri 2012 yılında yapılan Ghana Living Standards Survey Round Six (GLSS 6), Uydu görüntüleri ise Quickbird-2 multispektral uydu görüntüleri kullanılarak elde edilmiştir. Çalışma, bu verileri bir araya getirerek, gecekondu bölgelerini nicel olarak tanımlamak ve mahalle düzeyinde yoksulluk oranlarını tahmin etmiştir. Sonuçlar, gecekondu bölgelerinde yaşamın daha yüksek para yoksulluğu ile güçlü bir şekilde ilişkili olduğunu, ancak gecekondu bölgelerinde yaşayan herkesin yoksulluk içinde olmadığını göstermektedir. Çalışma, Afrika'nın alt-Sahra şehirlerinde etkili kentsel politikalar tasarlamak için önemli politika sonuçlarına sahiptir. Ayrıca gecekondu toplulukları içinde geniş bir

yoksulluk yelpazesinin olduğunu ve bu nedenle kentsel yoksullukla mücadele etmek için tek bir politika veya çözümün yeterli olmadığını göstermişlerdir.

Yanto vd. (2023) Endonezya'nın Batı Sumatra bölgesinde yoksulluk durumunu tahmin etmek ve sınıflandırmak için bir derin öğrenme yaklaşımı kullanarak bir analitik model geliştirmişlerdir. Çalışmanın veri seti 2020 ve 2021'de Batı Sumatra Eyaleti Merkezi İstatistik Kurumu'ndan alınmış olup K-ortalama yöntemi, yapay sinir ağı (YSA) ve destek vektör makinesi (DVM) kullanılarak bir analitik model geliştirilmiş ve Pearson korelasyon yöntemi kullanılarak optimize edilmiştir. Sonuçlar, önerilen derin öğrenme analiz modelinin tahmin ve sınıflandırma sürecinin gerçekleştirilmesinde etkili olan %99,8 doğruluk seviyesine ulaşmıştır. Araştırma bulguları yoksulluk sorunuyla ilgili ilk müdahaleye katkıda bulunmayı amaçlayarak, yoksulluk sorununu çözmek için hükümetlerin kullanabileceği bir araç olarak önerilen analitik model sunulmuştur.

Watmough vd. (2019) Kenya'nın kırsal kesiminde uydu verilerinin kullanarak ev halkı zenginliğini tahmin etmek için bir yöntem geliştirmeyi hedeflemişlerdir. Araştırma, uydu verilerinin ev halkı zenginliğini tahmin etmek için yüksek doğrulukla kullanılabileceğini ve çoklu seviyeli bir yaklaşımın tek seviyeli bir yaklaşımdan daha etkili olduğunu göstermektedir. Burada çoklu seviyeli yaklaşım ise uydu verileri, uzaktan algılama (remotely sensed) özellikleri olarak adlandırılan biyofiziksel parametreler ve arazi kullanımına/örtüsüne dayandırılmıştır. Tek seviyeli yaklaşımda modelin doğruluğu %38 iken çoklu yaklaşımda bu değer %45 olarak gerçekleşmiştir. Ayrıca, bu yöntemin yoksulluk ve gıda güvenliği gibi Birleşmiş Milletler 'in Sürdürülebilir Kalkınma Hedeflerini izlemek için kullanılabileceği belirtilmektedirler.

Olivia vd. (2011) Çin'in kırsal Shaanxi bölgesinde yoksulluk haritaları oluşturmak için küçük alan tahmini (small area estimation) tekniklerini kullanarak çevresel değişkenlerin yoksulluk oranları üzerindeki etkisini incelemişlerdir. Ayrıca, yoksulluk azaltma politikaları için yoksulluk haritalarının önemini tartışmak da amaçlanmıştır.

Çalışma, ev halkı ve çevresel değişkenleri kullanarak kırsal alanlarda yoksulluğu tahmin etmek için bir yöntem önermektedir. Çalışmada 2000 Nüfus Sayımı - 2001 Kırsal Hanehalkı ve Gelir Harcamaları Anketi - Çin Bilimler Akademisi veri merkezinden alınan çevresel değişkenler( kişi başı tüketim harcaması, yağış (mm/yıl), sıcaklık (derece celsius/yıl), rakım, arazi eğimi, toprak özellikleri (killi toprak ve organik madde içeriği), otoyol yoğunluğu ve otomatik model seçimi prosedürleri kullanılarak 87 aday değişken arasından seçilen değişkenler kullanılmıştır. Bu değişkenler üzerinde küçük alan tahmini aracılığıyla tüketim modelinin örneklem üzerinde tahmin edilmesini ve katsayıların daha sonra aynı değişkenler üzerindeki nüfus verilerine uygulanması sağlanmış böylelikle yoksulluk tahminleri için kullanılan verilerin aynı dağılıma sahip olması sağlanmıştır. Daha sonra çevresel değişkenler yoksulluk tahminlerine dahil edilerek yoksulluk ve çevre arasındaki teorik bağlantıları ve benzer özelliklere sahip insanların farklı coğrafi alanlarda farklı yoksulluk oranlarına sahip olabileceğine dair kanıtlar elde edilmiştir. Bu çalışmanın sonuçlarına göre, çevresel değişkenlerin yoksulluk tahminlerine dahil edilmesi, yoksulluk haritalarının doğruluğunu artırmış ve yoksulluk azaltma politikaları için daha etkili hedefleme yapılmasına olanak sağlamıştır. Ancak, çalışmada kullanılan veri setlerinin sınırlı olması ve örneklem büyüklüğünün küçük olması, sonuçların yalnızca Shaanxi bölgesi için geçerli olduğunu göstermektedir.

Pokhriyal ve Jacques (2017) Senegal'deki yoksulluk seviyelerini tahmin etmek için farklı veri kaynaklarını birleştiren bir hesaplama çerçevesi geliştiren araştırmacıların çalışmasını ve bu çalışmanın sonuçlarını anlatmaktadır. Makale, mobil telefon verileri, çevresel faktörler ve uydu görüntüleri gibi farklı veri kaynaklarının kullanımını ve bu verilerin bir araya getirilerek yoksulluk haritalarının oluşturulmasını ele almıştır. Bu veri kaynakları arasında mobil telefon verileri, çevresel faktörler ve uydu görüntüleri yer almaktadır. Ayrıca, makalede kullanılan değişkenler arasında nüfus yoğunluğu, gece ışıkları, NDVI (Normalized Difference Vegetation Index) ve GINI endeksi gibi farklı özellikler de yer almaktadır. Yoksulluk haritalandırma ile yoksullukla

mücadelede daha etkili yardım ve geliştirme programları tasarlanabileceğine, doğal afetler ve çatışmaların etkilerini izlemek için kullanılabilmesine değinmişlerdir.

Sheng ve Yumei (2021) üniversite öğrencilerinin yoksulluk seviyelerini tahmin etmek için bir makine öğrenimi modeli olan Rasgele Orman (RO) ile modelin doğruluğunu artırmak için özellik seçimi ve çıkarma tekniklerinden biri olan Temel Bileşenler Analizinden (TBA) yararlanmışlardır. Ayrıca çalışma, hedeflenmiş yoksulluk azaltma için üniversite öğrencilerinin yoksulluk seviyelerinin doğru bir şekilde belirlenmesinin önemini vurgulamak ve geleneksel tanımlama yöntemlerinin sınırlamalarını tartışmaktadır. Veri seti, Chuzhou Üniversitesi'ndeki yoksul öğrencilerin özelliklerini içermektedir. Veri setinde, yoksul öğrencilerin dört farklı yoksulluk seviyesi ve her bir öğrencinin 21 özelliği bulunmaktadır. Bu özellikler, öğrenciler tarafından Öğrenci Bilgi Yönetim Sistemi üzerinden doldurulmuştur ve 6 sürekli özellik ve 15 kategorik özellik içermektedir. Özellikler arasında borç miktarı, yıllık hanehalkı geliri, işsiz aile üyesi sayısı, çalışan sayısı, bakmakla yükümlü kişi sayısı, aile üyesi sayısı, kırsal faydalanıcılar, geçim yardımı, yetim olup olmadığı, tek ebeveynli çocuk, engelli kişilerin çocukları, engelli olup olmadığı, aile üyelerinde ciddi hastalık, ebeveynlerin çalışma yeteneğini kaybetmesi, yoksulluk kaydı, düşük gelirli aile, askeri personelin çocukları, doğal afetlerden etkilenenler ve kazalardan etkilenenler gibi özellikler yer almaktadır. Bu çalışmanın bulguları, RO-TBA modelinin yoksulluk seviyelerini tahmin etmek için diğer sınıflandırma algoritmalarına göre daha doğru sonuçlar verdiğini göstermektedir. Ayrıca, özellik seçimi ve çıkarma tekniklerinin kullanımının modelin doğruluğunu artırdığı ve modelin karmaşıklığını azalttığı görülmüştür. Çalışma, yoksulluk seviyelerinin doğru bir şekilde belirlenmesinin hedeflenmiş yoksulluk azaltma için önemli olduğunu vurgulamaktadır.

Browne vd. (2021) gelişmekte olan ülkelerde yoksulluk ve yetersiz beslenme yaygınlığını tahmin etmek için makine öğrenimi tekniklerini kullanmıştır. Bu makalede, açık erişimli veri kaynaklarından elde edilen özelliklerin kullanımıyla

yoksulluk ve yetersiz beslenme yaygınlığının çoklu tahminleri için yorumlanabilir rastgele orman modellerinin kullanımı gösterilmiştir. Yapay zekayı uygulayan yoksulluk tahmin modellerinde ilk kez güneş kaynaklı klorofil floresans verileri kullanılmıştır. Bu modeller, yoksulluk haritalama, coğrafi hedefleme veya izleme ve değerlendirme görevleri için kullanılabilen eşzamanlı tahmin ve erken uyarı sistemleri için sıralı tahmin görevleri için uygulanmıştır. 11 düşük ve alt orta gelirli ülkeden elde edilen verilerle uygulanan bu modeller, önceden çalışmalarda kullanılan özel veri ve/veya derin öğrenme yöntemlerine kıyasla benzer tahmin doğruluğu sağlamıştır. Ayrıca, makalede, fiziksel coğrafya özelliklerinin tahmin performansına en çok katkıda bulunduğu ve iyi bir mekansal verinin önemini vurguladığı belirtilmiştir.

Hu vd. (2022) yüksek çözünürlüklü görüntüler, Açık Sokak Haritası (ASH) verileri ve dijital yüzey modeli verilerini kullanarak köy düzeyinde yoksulluğu belirlemek için bir yaklaşım önermektedirler. Çalışma, Çin'in Hubei Eyaleti'ndeki Yunyang İlçesi'nde gerçekleştirilmiştir. Makalede kullanılan değişkenler üç boyutta incelenmiştir: erişim olanakları ve hizmetler, tarımsal üretim koşulları ve sosyoekonomik koşullar. Günlük ihtiyaçlara erişim ve her köyün pazar katılımını ölçmek için en yakın markete olan zaman maliyeti kullanılmıştır. Tarımsal üretim koşulları boyutunda; tarım arazisi oranı, orman oranı, rakım ve %25 eğimden fazla yamaçlara sahip arazi oranı kullanılmıştır. Sosyoekonomik koşullar boyutunda ise, nüfus yoğunluğu, ortalama yıllık gelir ve okuryazarlık oranı gibi değişkenler kullanılmıştır. Rastgele orman algoritmasını kullanarak yoksulluk ile açıklayıcı değişkenler arasındaki ilişkiyi modellemişlerdir. Sonuçlar, köy düzeyinde yoksulluğu tahmin etmede %54 doğruluk göstermektedir. Bu çalışma, çoklu kaynaklı coğrafi verilerin yoksulluk haritalama konusundaki potansiyelini göstermeyi amaçlamıştır. Ayrıca, çalışmanın sonuçlarına göre, köy düzeyinde yoksulluğun belirlenmesinde en önemli faktörler arasında, en yakın tesislere ve hizmetlere erişim süresi, yapılan arazi kullanımı, köy yerleşimlerinin dağılımı ve köylerdeki ortalama gelir gibi faktörler yer almaktadır.

Solis-Salazar ve Madrigal-Sanabria (2022) geleneksel yöntemlerin yüksek hata oranlarına sahip olduğu yoksulluk tahminlerinde makine öğrenimi modeli kullanarak daha doğru sonuçlar elde etme amacıyla, XGBoost tabanlı bir makine öğrenimi modeli önermiş ve bu model, Costa Rica'daki 2019 hanehalkı anketinden elde edilen verilerle test edilmiştir. XGBoost algoritmasının yoksulluk, aşırı yoksulluk ve kırılabilirlik tahmininde geleneksel yöntemlere göre daha iyi performans gösterdiği sonucuna varılmıştır (Modelde %74 doğruluk elde edilmiştir). Meslek ve ev aletleri göstergelerinin yoksulluk tahmininde önemli bir rol oynadığı görülmüştür. Ancak, bazı durumlarda geleneksel yöntemlerin daha iyi sonuçlar verdiği de görülmüştür. Bu nedenle, makine öğrenimi modellerinin kullanımının, yoksulluk tahmininde geleneksel yöntemlerin yerini tamamen alamayacağını, ancak daha doğru sonuçlar elde etmek için kullanılabileceğini öne sürmüşlerdir.

Xiao (2021) üç Afrika ülkesinde yoksulluk seviyelerini, tüketim verileri, gündüz ve gece uydu görüntüleri ve bir VGG-11 ağı kullanarak tahmin etmek için transfer öğrenimi, derin öğrenme ve rastgele orman algoritması kullanan bir makine öğrenimi modeli sunmuştur. Hiper parametre ayarlama ve model yorumlaması kullanılarak modelin performansını ve yorumlanabilirliğini artırmayı amaçlamıştır. Veri seti, Yaşam Standartları Ölçüm Çalışması Anketi'nden elde edilen verileri içermektedir: 2016-2017 Malavi verileri, 2015-2016 Etiyopya verileri ve 2015-2016 Nijerya verileri. Modelin başarısı, çalışmanın farklı aşamalarında ölçülmüştür. İlk olarak, modelin başlangıçtaki R2 skoru, Etiyopya için %15, Nijerya için %18 ve Malavi için %27 olarak ölçülmüştür. Daha sonra, hiperparametre ayarlama kullanılarak modelin performansı iyileştirilmiş ve R2 skoru, Etiyopya için %47, Nijerya için %58 ve Malavi için %34'e yükseltilmiştir. Bu sonuçlar, modelin başarılı bir şekilde eğitildiğini ve yoksulluk seviyelerini doğru bir şekilde tahmin edebildiğini göstermektedir. Ayrıca, modelin yorumlanabilirliği artırılmış ve özellik önem çalışmaları kullanılarak modelin performansı daha da iyileştirilmiştir. Sonuç olarak, bu çalışma, derin öğrenme ve uydu

görüntüleri kullanarak yoksulluk seviyelerini analiz etmek için pratik bir yöntem sunmaktadır ve modelin başarılı bir şekilde eğitildiğini göstermektedir.

Tingzon vd. (2019) makine öğrenimi, uydu görüntüleri ve kalabalık kaynaklı coğrafi bilgi kullanarak Filipinler'deki yoksulluğu haritalandırmak ve dört sosyoekonomik göstereyi tahmin etmek (zenginlik düzeyi, eğitim yılı, elektrik erişimi ve su erişimi) üzerine bir araştırma yapmışlardır. Çalışma, makine öğrenimini coğrafi verilerle birleştirerek ayrıntılı yoksulluk tahminleri sağlayabileceğini ve Açık Sokak Haritalarından (ASH) gönüllü coğrafi bilgi ve gece ışıkları uydu görüntülerinden yararlanılan maliyet etkin bir yaklaşım önermektedir. En iyi modeller, varlık temelli zenginliğin yaklaşık %63'ünü açıklamaktadır ve gönüllü olarak hazırlanan coğrafi verilerle eğitilen modeller, özel uydu görüntüleri kullanılarak eğitilenlerle aynı tahmin performansını sağlamaktadır. Çalışma, uydu görüntüleri ve kalabalık kaynaklı coğrafi verilerin Filipinler'deki yoksulluğu tahmin etmek için değerli araçlar olduğunu ve yüksek çözünürlüklü, gerçek zamanlı yoksulluk haritalandırması için kullanılabilirliğini göstermektedir.

Kshirsagar vd (2017) çalışmasında veri açısından yetersiz olan ülkelerde yoksul haneleri belirlemek için kullanılan bir yöntem olan Yoksulluk Olasılık İndeksi'nin (PPI) metodolojisini açıklamaktadır. Makale, standart istatistiksel öğrenme tekniklerini kullanarak, aşırı uyum sorununu azaltmak ve veri toplama maliyetlerini en aza indirmek için en fazla on soruya kadar soru sayısını sınırlayan bir yöntem sunmaktadır. PPI, 60 ülke için geliştirilmiş ve dünya çapında yaklaşık 600 kuruluş tarafından kullanılmaktadır. Makale ayrıca, seçilen 10 soruya ağırlık atayarak basit bir skor kartı yaklaşımıyla yoksulluk durumunu tahmin etmek için bir metodoloji sunmaktadır. Çalışma, yoksulluk durumunu tahmin etmek için Proxy-Means Testi (PMT) adı verilen bir metodoloji önermektedir. Bu metodoloji, ulusal örneklemli bir hanehalkı anketinden değişkenlerin bir alt kümesini seçerek, bu değişkenleri kullanarak hanehalkı düzeyinde yoksulluğu tahmin etmek için bir model tahmin eder.

Tahmin edilen model daha sonra bir skor kartına çevrilir ve elde edilen PMT, yoksul haneleri belirlemek için kullanılır. Çalışmanın veri seti, 2015 Zambiya Yaşam Koşulları Ölçüm Anketi'nden oluşmaktadır. PMT metodolojisinin, yoksulluk durumunu tahmin etmek için kullanılan geleneksel yöntemlere göre daha doğru sonuçlar verdiği gözlenmiş, düşük maliyetli ve hızlı bir şekilde geliştirilebilir olduğu belirtilmiştir.

Das vd. (2020) geleneksel veri toplama yöntemlerinin yavaş ve etkisiz olduğu Hindistan'da yüksek ve orta çözünürlüklü uydu görüntülerinin yoksulluğu tahmin etmek için kullanımı incelemişlerdir. Makale, evrensel sinir ağları gibi makine öğrenimi araçlarının, yoksullukla ilgili sosyo-ekonomik göstergeleri tahmin etmeye yardımcı olan görüntü özelliklerini etkili bir şekilde tanımlamak için nasıl kullanıldığını gözden geçirmektedir. Çalışmada kullanılan veri seti; uydu görüntüleri ve sosyo-ekonomik göstergelerdir. Uydu görüntüleri, yoksulluk ve kentselleşme gibi faktörleri tahmin etmek için kullanılmıştır. Sosyo-ekonomik göstergeler ise yoksullukla ilgili verileri tahmin etmek için kullanılan geleneksel yöntemlerin eksikliğini tamamlamak için kullanılmıştır. Gündüz uydu görüntüleri, evrimsel sinir ağları ve ridge regresyon kullanılarak yoksulluk ile ilgili daha fazla özelliğin çıkarılabileceğinin ve doğru sonuçlar üretilebileceğinin bilgisine ulaşılmıştır. Toplanan çözümler, politika yapıcıların etkili yoksullukla mücadele programları oluşturmak için kullanabilecekleri bir araç olup yoksulluk haritalama için uydu görüntüleri ve makine öğreniminin kullanımını destekleyen çeşitli çalışmalara referans olması hedeflenmiştir.

Ayush vd. (2020) yüksek çözünürlüklü uydu görüntüleri ve makine öğrenimi kombinasyonunun sürdürülebilirlikle ilgili görevlerde faydalı olduğu ancak yüksek çözünürlüklü görüntülerin maliyetinin yaygın kullanım için bir engel olduğu belirtilmektedir. Bu nedenle, araştırmacılar, yüksek maliyetli yüksek çözünürlüklü görüntüleri dinamik olarak belirlemek için ücretsiz düşük çözünürlüklü görüntüler

kullanarak bir takviyeli öğrenme yaklaşımı önermektedirler. Veri setindeki değişkenler, yüksek çözünürlüklü uydu görüntüleri kullanılarak elde edilen sınıf bazlı nesne sayılarıdır (binalar, kamyonlar, yolcu araçları, demiryolu araçları vb.). Ayrıca bu görüntülerin sezonluk değişimleri de analiz edilmiştir. Bu yaklaşım, Uganda'da yoksulluk tahmini için uygulanmış ve yüksek çözünürlüklü görüntülerin sayısını %80 azaltırken doğruluğu koruduğu ve artırdığı gösterilmiştir. Makale, yoksulluk tahmininde verimli yüksek çözünürlüklü uydu görüntüsü elde etmek için uyumlu bir çerçeve önermektedir. Bu çerçeve, yüksek çözünürlüklü uydu görüntülerinin elde edilmesini daha verimli hale getirebilmekte ve maliyetleri azaltabilmektedir. Ayrıca, önerilen yöntemin, sürdürülebilirlikle ilgili diğer görevlerde de kullanılabilceğini belirtmişlerdir.

Piaggese vd. (2019) yüksek çözünürlüklü uydu görüntüleri kullanarak kentsel yoksulluğu tahmin etmek için derin öğrenme yöntemlerinin kullanılabilirliğini araştırmıştır. Çalışma önceden eğitilmiş bir modelin kullanımını ve yeni test şehirlerinde hedefin tahmin edilmesini içeren bir dizi deneyi içermektedir. Ayrıca, makale, farklı özelliklerin kullanımı ve farklı ölçeklerde tahminlerin yapılması gibi farklı yaklaşımların performansını da karşılaştırmaktadır. Buna istinaden derin öğrenme metotlarına ek olarak Ridge regresyonda kullanılmıştır. Veri setinde, iki gelişmiş ülkedeki (ABD ve İtalya) farklı şehirlerden yüksek çözünürlüklü uydu görüntüleri ve yoksulluk seviyeleri toplanmıştır. Deneylerde elde edilen R2 skorlarına göre, modellerin başarı yüzdesi çok fazla değişkenlik göstermektedir. Makale, yoksulluk haritalama ve tahmin etme konusunda derin öğrenme yöntemlerinin kullanımının potansiyelini göstermekte iken derin öğrenme yöntemlerinin kullanımının daha fazla araştırılması ve geliştirilmesi gerektiğine de vurgu yapmaktadır.

Babenko vd. (2017) Meksika'da yoksulluğu tahmin etmede haritalama yapmak için evrişimli sinir ağları ile yüksek ve orta çözünürlüklü uydu görüntülerini

kullanmışlardır. Makalede kullanılan veri seti, Meksika'da bulunan 3000'den fazla yerleşim yerinin yoksulluk seviyelerini içermektedir. Bu veri seti, Ulusal İstatistik ve Coğrafi Bilgi Enstitüsü tarafından toplanmıştır. Yüksek ve orta çözünürlüklü uydu görüntüleri Landsat 8 ve Sentinel-2 uydu sistemleri tarafından sağlanmıştır. Makalede kullanılan değişkenler arasında, uydu görüntülerinden elde edilen indeksler gibi çevresel değişkenler, yerleşim yerlerinin nüfusu, eğitim seviyesi, işsizlik oranı ve ev sahipliği yapan hanehalklarının gelir düzeyi gibi sosyoekonomik değişkenler de kullanılmıştır. Çalışmada yoksulluk haritalaması yapmak için iki farklı model kullanılmıştır: birincisi, yüksek çözünürlüklü uydu görüntülerini kullanan bir model ve ikincisi hem yüksek hem de orta çözünürlüklü uydu görüntülerini kullanan bir model. Her iki model de evrişimli sinir ağı (CNN) kullanılarak eğitilmiştir. Yüksek çözünürlüklü modelin doğruluk oranı %85, orta ve yüksek çözünürlüklü modelin doğruluk oranı ise %90 olarak rapor edilmiştir. Bu sonuçlar, uydu görüntüleri kullanarak yoksulluk haritalaması yapmanın etkili bir yöntem olabileceğini göstermektedir.

Robinson vd. (2017) araştırmasında geleneksel yoksulluk haritalama tekniklerinin sınırlarını tartışmakta ve hanehalkı anket verilerini çevresel değişkenlerle birleştirerek yoksulluğun dağılımını daha iyi anlamak ve tahmin etmek için bir çevresel yaklaşım önermektedir. Makalede, Uganda'da ev harcaması verilerini uydu türetilmiş çevresel değişkenlerle bağlantılı olarak ayırt edici analitik yöntemler kullanılarak haritalar oluşturulmuştur. Uganda'daki yoksulluk haritalaması için kullanılan veri seti, 2002/2003 Uganda Ulusal Hanehalkı Anketi'nden gelen ev harcaması verileridir. Bu veriler, GPS kullanılarak coğrafi konumlara atanmış 9.711 hanehalkından oluşmaktadır. Bu değişkenler arasında, ortakızılötesi verileri, yüzey sıcaklığı, Normalized Difference Vegetation Index (NDVI), hava sıcaklığı, buhar basıncı açığı ve soğuk bulut süresi gibi değişkenler yer almaktadır. Makalede, Uganda'da yoksulluk haritalaması için kullanılan modeller, diskriminant analiz yöntemi kullanılarak oluşturulmuştur. Modeller, farklı mekansal çözünürlüklerde (0.01 ila 1.0 derece

arasında) oluşturulmuştur. Modellerin başarısı, kappa ve r2 istatistikleri kullanılarak ölçülmüştür. Makalede belirtilen bilgilere göre, çevresel yaklaşımın, geleneksel küçük alan tahminlerine benzer bir başarı elde ettiği ve yaklaşık 0.20 ila 0.30 derece arasında bir mekansal çözünürlükte yoksulluk verilerinin varyansının %50'den fazlasını açıkladığı belirtilmiştir.

Afzal vd. (2015) Pakistan ve Sri Lanka'daki yoksulluk oranlarını tahmin etmek için değişken seçimi yöntemlerini karşılaştırmaktır. Makale, manuel seçim, ileri adımlı regresyon ve Lasso tabanlı prosedürler gibi üç farklı yöntemi test etmektedir. Veri setleri, Pakistan'da 2010-2011 Pakistan Social and Living Standards Measurement Survey (PSLM) ve Sri Lanka'da 2012-2013 Household Income and Expenditure Survey (HIES) verileridir. Lasso'nun diğer yöntemlere göre daha iyi performans gösterdiği bulunmuştur. Pakistan'da, manuel seçim yöntemi en iyi performansı göstermiştir ve ortalama bölgesel hata oranı %2,5 iken Sri Lanka'da, Lasso yöntemi en iyi performansı göstermiştir ve ortalama bölgesel hata oranı %1,9 civarında gerçekleşmiştir.

Mwabu vd. (2003) yeni bir ev hanehalkı araştırması yapmadan, bir yıl için anket verilerinden türetilen yoksulluk endekslerini kullanarak sonraki dönemler için yoksulluk oranlarını tahmin etmek için bir yöntem geliştirmektedir. Bu yöntem, Kenya'daki ev hanehalkı anketlerinden elde edilen veriler kullanılarak gösterilmektedir. Yöntem temelde regresyon modeli olup, ekonomik büyüme ve gelir dağılımındaki değişikliklere dayanmaktadır ve GSYİH büyümesi ve gelir dağılımıyla ilgili veriler hükümet belgelerinden ve yayınlanmış literatürden elde edilmektedir. Sonuçlar, Kenya'da yoksulluğun 1997 ile 2000 yılları arasında arttığını ve kırsal alanların kentsel alanlardan daha fazla artış yaşadığını göstermektedir.

Herandez vd. (2017) Guatemala'nın güneybatı bölgesindeki beş idari bölgede yapılan bir çalışmada, cep telefonu verilerinin kullanımıyla yoksulluk oranlarını tahmin etmek

ve geleneksel veri toplama yöntemlerine kıyasla daha düşük maliyetle yoksulluk tahminlerinin yapılabildiğini göstermeyi amaçlamaktadır. Makalede kullanılan veri seti, Guatemala'nın güneybatı bölgesindeki beş idari bölgede yapılan bir çalışmadan elde edilen cep telefonu verileridir. Değişkenler arasında, Call Detail Record (CDR) verilerinden elde edilen cep telefonu kullanımı, arama süresi, arama yoğunluğu, arama yönü, arama sıklığı, arama saatleri ve arama yerleri gibi değişkenler yer almaktadır. Ayrıca, yoksulluk oranlarını tahmin etmek için kullanılan diğer değişkenler arasında, nüfus yoğunluğu, eğitim düzeyi, işsizlik oranı, ev sahipliği yapma oranı ve elektrik kullanımı yer almaktadır. Makalede, farklı modellerin kullanıldığı belirtilmektedir. Regresyon teknikleri ve sınıflandırma modelleri kullanılmıştır. En iyi modeller, 2006 yılındaki toplam yoksulluk seviyelerini %76'lık bir R2 değeri ile tahmin etmiştir. Sınıflandırma modelleri için F1 skorları, üç ayrı kategori (düşük, orta ve yüksek yoksulluk oranları) dikkate alındığında %84'e kadar çıkmıştır. Ancak, kırsal verilerin 2011 yılı için tahmin edilmesi durumunda, regresyon teknikleri için R2 sonuçları 0.46'ya kadar düşmüştür. Sınıflandırma sonuçları, özellikle üç sınıf dikkate alındığında, tüm modellerde regresyon sonuçlarından daha iyi olmuştur. Makalenin sonucunda, cep telefonu verilerinin kullanımıyla yoksulluk oranlarının tahmin edilebileceği ve geleneksel veri toplama yöntemlerine kıyasla daha düşük maliyetle yoksulluk tahminlerinin yapılabilmemesinin mümkün olduğu ifade edilmektedir.

## ÜÇÜNCÜ BÖLÜM

### YAPAY ZEKA ÇERÇEVESİ VE UYGULAMA

#### 3.1. Yapay Zeka Modelleri

Hanehalkı yoksulluk düzeyinin tahmini, bir ülkenin sosyo-ekonomik durumunu anlamaya yardımcı olmaktadır. Bu tahminler, ülkedeki yoksulluğun ne kadar yaygın olduğunu ve hangi bölgelerde daha fazla olduğunu göstermektedir. Bu bilgi, ülkede yoksulluğu azaltmak için yapılacak çalışmaların, geliştirilecek politikaların daha etkili olmasını sağlayabilmektedir. Ayrıca, hanehalkı yoksulluk düzeyinin tahmini, ülkedeki insanların yaşam koşulları hakkında da bilgi vermektedir. Bu bilgi, ülkenin sosyal ve ekonomik gelişimine ilişkin önemli bir göstergedir. Makine öğrenmesi algoritmaları ve yapay sinir ağlarının kullanılması, bu tahminleri yaparken daha doğru sonuçlar elde edilmesini sağlamaktadır. Bu algoritmalar ve ağlar, verileri analiz ederek benzer özelliklere sahip hanehalklarının yoksulluk düzeyini tahmin edebilmektedir. Bu sayede, hanehalkı yoksulluk düzeyinin tahminlerinde daha yüksek bir doğruluk oranına kısa zamanda ulaşılması mümkün olacaktır. Bu bağlamda çalışmada; Türkiye için hanehalkı yoksulluk düzeyinin hane değişkenleri üzerinden, çağımızın getirdiği yapay zeka çerçevesi ile uygulaması gerçekleştirilecektir.

Yoksulluk çizgisi belirlendikten sonra bu çizgiyi oluşturarak yoksulluk düzeyini etkileyen değişkenleri keşfetmek amacıyla, Türkiye örneği için en doğru yoksulluk sınıflandırmasının hangi modeller aracılığıyla yapılabileceği 9 farklı makine öğrenmesi algoritması ve yapay sinir ağı modeli ile denenecektir. Kullanılacak makine öğrenmesi algoritmaları: Karar Destek Makinesi, K En Yakın Komşu, Naive Bayes (Gaussian), Karar Ağacı, Rasgele Orman, XGBoost, LightGBM, Ada Boost, Gradyan Arttırma ve yapay sinir ağlarından olan Çok Katmanlı Algılayıcı (Multilayer perceptron-MLP)'dir.

### 3.1.1. Destek Vektör Makinesi

Destek Vektör Makinesi (DVM), bir sınıflandırma algoritmasıdır (Yang vd., 2011). DVM'ler, veri noktalarını iki sınıfa ayırma yapmak için bir hiper düzleme uygun şekilde eğitilir. Bu hiper düzlemin veri noktalarını en iyi şekilde ayırdığı yer, DVM'nin "kesme düzlemi" olarak adlandırılan bir eşitlikle ifade edilebilir. Bu eşitlik aşağıdaki formülle ifade edilebilir:

$$w \cdot x + b = 0 \quad (1)$$

Burada,  $w$  ve  $b$  DVM'nin eğitimi sırasında öğrenilen parametrelerdir ve  $x$  veri noktalarını temsil eder. Bu eşitlik, veri noktalarının  $wx + b$  değerlerine göre sınıflandırılmasını sağlar. Eğer  $wx + b > 0$  ise, veri noktası birinci sınıfı temsil eder. Eğer  $wx + b < 0$  ise, veri noktası ikinci sınıfı temsil eder. Eğer  $wx + b = 0$  ise, veri noktası hiper düzlemin üstündedir ve bu noktaya "destek vektörü" denir. Bu sınıflandırma işlemi aşağıdaki formülle ifade edilebilir:

$$h(x_i) = \begin{cases} +1 & \text{if } wx + b \geq 0 \\ -1 & \text{if } wx + b < 0 \end{cases} \quad (2)$$

DVM'ler, veri noktalarını en iyi şekilde ayırtan hiper düzlemi bulmak için çeşitli optimizasyon problemlerini çözmektedir. Bu optimizasyon problemleri, veri noktalarını mümkün olan en iyi şekilde ayırtan hiper düzlemin "genişliği" olarak adlandırılan bir ölçütü en büyük yapmayı amaçlamaktadır. Bu genişlik, hiper düzlemin iki yanındaki veri noktaları arasındaki mesafeyi ifade eder ve DVM'lerin çözdükleri optimizasyon problemlerinin amacı bu mesafeyi mümkün olan en büyük yapmaktır. Bu sayede, DVM'ler veri noktalarını en iyi şekilde ayırtan ve en az hata ile sonuç veren hiper düzlemi bulabilmektedir.

### 3.1.2. K En Yakın Komşu Algoritması

K En Yakın Komşu (KNN), bir sınıflandırma algoritmasıdır. KNN algoritması, verilen bir veri noktasının sınıfını, o veri noktasının en yakın  $k$  komşusuna göre

belirler. Bu komşular, veri kümesinde bulunan diğer veri noktalarıdır ve veri noktasının "öteki" veri noktalarına olan uzaklığına göre sıralanır (Mandrell vd., 2020).

KNN algoritmasının çalışma şekli, veri noktasının sınıfını belirlemede kullandığı uzaklık ölçümüne göre değişebilir. Örneğin, veri noktalarının uzaklığının ölçümü için en sık kullanılan ölçüt Öklid Uzaklığıdır. Bu ölçütün formülü aşağıdaki gibidir:

$$d(x, y) = \sqrt{\sum_{i=1}^k (x_i - y_i)^2} \quad (3)$$

Burada, x ve y veri noktalarını temsil eder. Bu formül, iki veri noktası arasındaki uzaklığı hesaplamaya yarar.

KNN algoritmasının çalışma şekli, veri noktasının sınıfını belirlemede kullandığı k değerine de göre değişebilir. Örneğin, eğer k değeri 1 ise, veri noktasının sadece en yakın komşusu dikkate alınır ve veri noktası o komşunun sınıfı olarak sınıflandırılır. K değerinin artırılması, veri noktasının sınıfını belirlerken dikkate aldığı komşuların sayısını artırır ve bu sayede sınıflandırma işleminin daha istikrarlı hale gelmesine yardımcı olur. Ancak, k değerinin çok büyük olması, veri noktasının çevresindeki veri noktalarının çok fazla sayıda olduğu durumlarda sınıflandırma işleminin yavaş hale gelmesine yol açabilir. Bu nedenle, KNN algoritmasının çalışma şeklini belirlemek için uygun bir k değerinin seçilmesi önemlidir.

### 3.1.3. Naive Bayes (Gaussian) Algoritması

Naive Bayes, bir sınıflandırma algoritmasıdır. Naive Bayes algoritması, verilen bir veri noktasının sınıfını belirlemek için Bayes Teoremi'ni kullanır. Bayes Teoremi aşağıdaki formülle ifade edilebilir:

$$P(A|B) = (P(B|A) * P(A)) / P(B) \quad (4)$$

Burada, P(A|B) A olayının B olayının gerçekleştiği koşullar altında olasılığını ifade eder. P(B|A) ise B olayının A olayının gerçekleştiği koşullar altında olasılığını ifade

eder.  $P(A)$  ise A olayının olasılığını ifade eder ve  $P(B)$  ise B olayının olasılığını ifade eder.

Naive Bayes algoritması, verilen bir veri noktası için hangi sınıfın olasılığının daha yüksek olduğunu belirlemek için Bayes Teoremi'ni kullanır (Prajapati & Patle, 2010). Örneğin, veri kümesinde iki sınıf varsa (sınıf 1 ve sınıf 2) ve verilen bir veri noktası için sınıf 1'in olasılığının sınıf 2'nin olasılığından daha yüksek olduğu tespit edilirse, veri noktası sınıf 1 olarak sınıflandırılır.

#### **3.1.4. Karar Ağacı Algoritması**

Karar Ağacı bir veri modelleme tekniğidir. Bu teknik, bir veri kümesine dayanarak bir sonuç elde etmek için veriler üzerinde bir sıralama yapar ve verileri sınıflandırır. Karar ağacı, veri kümesinden öğrenilen kuralları bir ağaç yapısına dönüştüren bir algoritmadır. Ağaç yapısının dalları ve düğümleri verileri sınıflandırmak için kullanılır ve bu sınıflandırma sonucu olarak veri kümesinden çıkan sonuç elde edilir. Karar ağacı, veri kümesinden elde edilen sonuçları tahmin etmek ve veri kümesine dayalı bir karar vermek için kullanılabilir (Sajja, 2021). Veri kümesi, ağaç yapısının dalları ve düğümleri kullanılarak sınıflandırılır ve bu sınıflandırma sonucu olarak veri kümesinden çıkan sonuç elde edilir.

#### **3.1.5. Rasgele Orman Algoritması**

Rastgele Orman Algoritması, makine öğrenimi alanında yaygın bir popülerlik kazanmış olan güçlü ve çok yönlü bir topluluk öğrenme yöntemidir. Algoritma özünde, her biri eğitim verilerinin rastgele bir alt kümesi ve özelliklerin rastgele bir alt kümesi üzerinde eğitilmiş birden fazla karar ağacını birleştirir (Sajja, 2021). "Rastgele ormanlar" olarak bilinen bu karar ağaçları topluluğu oluşturma yaklaşımı, geleneksel karar ağacı algoritmasına ek bir rastgelelik katmanı ekleyerek daha iyi performans ve sağlamlık kazandırmaktadır.

Rastgele Orman Algoritmasının arkasındaki temel fikir, daha doğru ve istikrarlı bir model oluşturmak için toplu öğrenmenin gücünden yararlanmaktır. Algoritma, birden

fazla karar ağacının tahminlerini bir araya getirerek, bireysel modellerin varyansını azaltabilir ve bu da yeni, görülmemiş veriler üzerinde gelişmiş genelleme sağlamaktadır (Biau & Scornet, 2016).

### **3.1.6. XG Boost Algoritması**

XGBoost (eXtreme Gradient Boosting), bir makine öğrenimi algoritmasıdır. XGBoost, özellikle kategorik veri tahminleri yapmak için kullanılır ve genellikle diğer makine öğrenimi algoritmalarından daha iyi sonuçlar vermektedir (Koduru, 2020). XGBoost, "gradient boosting" adı verilen bir tahmin yöntemine dayanır. Gradient Boosting, veri kümesinde gizli bir modele (öğrenme modeline) ulaşmak için bir sıralama yöntemidir. Model, veri kümesindeki özelliklerin bir fonksiyondan geçirilerek tahmin edilmesini sağlar. XGBoost algoritması veri kümesinde gizli olan bir modele ulaşmak için gradient boosting yöntemini kullanır ve modelin tahminlerinin doğruluğunu maksimize etmeyi hedefler. Bu sayede, kategorik veri tahminleri yaparken daha iyi sonuçlar elde edilebilir.

### **3.1.7. Light GBM Algoritması**

LightGBM, bir makine öğrenimi algoritmasıdır. LightGBM, XGBoost gibi gradyan arttırma adı verilen bir tahmin yöntemine dayanır ve genellikle diğer makine öğrenimi algoritmalarından daha hızlı sonuçlar vermektedir (Daoud, 2019). LightGBM, veri kümesinde gizli olan bir modele ulaşmak için gradyan arttırma yöntemini kullanır ve modelin tahminlerinin doğruluğunu maksimize etmeyi hedefler. LightGBM, özellikle kategorik veri tahminleri yapmak için kullanılır ve genellikle XGBoost gibi diğer makine öğrenimi algoritmalarından daha iyi sonuçlar verir.

### **3.1.8. Ada Boost Algoritması**

AdaBoost (Adaptive Boosting), bir makine öğrenimi algoritmasıdır. AdaBoost, çok sayıda zayıf öğrenme modelinin bir araya getirilerek daha güçlü bir öğrenme modeli oluşturulmasını hedefler (Chen & Guestrin, 2016). Zayıf öğrenme modeli, veri kümesinde gizli olan bir modele ulaşmak için yöntemler kullanır ancak bu yöntemlerin

başarı oranı düşüktür. AdaBoost, bu zayıf öğrenme modellerini bir araya getirerek daha güçlü bir öğrenme modeli oluşturmaktadır.

### **3.1.9. Gradyan Arttırma Algoritması**

Gradyan Arttırma, bir makine öğrenimi algoritmasıdır ve veri kümesinde gizli olan bir modele ulaşmak için bir sıralama yöntemidir. Model, veri kümesindeki özelliklerin bir fonksiyondan geçirilerek tahmin edilmesini sağlar. Gradyan Arttırma, tahminleri yaparken önceki tahminlerin doğruluğuna göre ağırlık değerleri atar. Doğru tahminler için ağırlık değeri yükseltilir ve yanlış tahminler için ağırlık değeri düşürülür (Hang vd., 2021).

### **3.1.10. Çok Katmanlı Algılayıcı (Multilayer Perceptron-MLP)**

Yapay sinir ağı, derin öğrenme yöntemlerinden biridir ve insan beyninin çalışma yapısına dayanmaktadır. Girdiler ve ağırlıklar aracılığıyla verileri işleyerek öğrenme yapabilen ve belirli bir problem çözebilen bir modelleme yöntemidir.

Yapay sinir ağı, birkaç çok sayıda işlemsel elemanın (nöronların) bir araya gelmesi ile oluşmaktadır. Her bir nöron girdi verilerini alır, ağırlıklar ile çarpar ve bir yanlılık değerini ekler. Bu işlem sonucu oluşan toplam değer, bir aktivasyon fonksiyonu tarafından işlenir ve çıktı olarak bir sonraki katmana gönderilir. Bu işlem, ağıdaki her bir katman arasında tekrarlanır ve sonunda, ağın çıktısı oluşur. Yapay sinir ağı, veriler üzerinde eğitildiğinde ağırlıklar ve yanlılık değerleri güncellenerek, belirli bir problemi çözmede daha iyi hale gelmektedir.

Temel bir yapay sinir ağı türü olan Çok Katmanlı Algılayıcı (MLP), çok çeşitli karmaşık problemleri çözmek için güçlü ve çok yönlü bir yaklaşım sunarak makine öğrenimi alanında bir köşe taşıdır (Taud & Mas, 2017). Özünde, Çok Katmanlı Algılayıcı, verilerin giriş katmanından gizli katmanlar aracılığıyla çıkış katmanına tek bir yönde aktığı ileri beslemeli bir sinir ağıdır.

## 3.2. Metodoloji

### 3.2.1. Veri

Çalışmada TÜİK tarafından asıl adı ile Hanehalkı Bütçe Araştırması Tüketim Harcamaları Birleşik Mikro Veri Seti olan Hanehalkı Bütçe Anketi 2019 yılı verileri kullanılmıştır. Hanehalkı Bütçe Anketleri, hanelerin sosyo-ekonomik yapıları, yaşam düzeyleri ve tüketim kalıpları hakkında bilgi veren, uygulanan sosyo-ekonomik politikaların geçerliliğinin test edilmesi amacıyla kullanılan en önemli kaynaklardan biridir (TÜİK, 2020).

TÜİK tarafından 2019 yılında 11.521 hanehalkına uygulanmıştır. Coğrafi kapsamı Türkiye Cumhuriyeti sınırları içinde bulunan tüm yerleşim yerleridir. Nihai örnekleme birimi olarak örnek adreste bulunan hanehalkı tanımlanmıştır. Tabakalı iki aşamalı küme örnekleme yöntemi kullanılmıştır. Cevapsızlık oranı ise Türkiye genelinde %25,9 olarak gerçekleşmiştir (TÜİK, 2019).

Çalışma kapsamında anket verilerinden hanehalklarına ilişkin sosyo-ekonomik değişkenler ve hane değişkenleri baz alınmıştır. Fertlere ait tüketim verileri dahil edilmemiştir.

Veri setinde hedef değer bulunmadığından, bu çalışma için hedef değeri 2019 yılı için hesaplanan yıllık ortalama hanehalkı kullanılabilir geliri 51,873 Türk Lirası olarak belirlenmiştir. Daha sonrasında hanehalkı gelirine ilişkin değişken, modelde aşırı öğrenmeye sebep olmaması açısından veri setinden çıkarılmıştır.

Anket verilerinde, Türkiye'deki ortalama hane yapısının sapmasını ciddi derecede etkileyecek, kullanılacak olan modellerin sapmasının yüksek olmasına sebep olacak ve dolayısıyla düşük başarı gösterecek çeşitli değişkenler keşfedici analizler doğrultusunda yapılan dağılım ve sapma analizleri sonucunda kapsam dışı bırakılmıştır. Bu değişkenlerden bazıları şunlardır; sahip olunan sera ve otel sahipliği, çöp öğütücü sahipliği, telefon hattı sayısı vb.

**Tablo 3.2.1. Çalışmada kullanılan değişken adları ve açıklamaları**

<i>Değişken No</i>	<i>Değişken Adı</i>	<i>Değişken Açıklaması</i>
1	HH_TIP_HBA	Hanehalkı tipi
2	KONUT_TIP	Oturulan konutun tipi
3	MULKIYET	Konuta mülkiyet durumu
4	KIRA_TUTAR	Aylık ödenen kira tutarı
5	KIRA_IZAFI	İzafi kira
6	KONUT_PİYASA_DEGER	Konutun piyasa değeri
7	BINA_YIL	Binanın yapılış tarihi
8	ODA_SAYI	Oda sayısı
9	KONUT_ALAN	Konutun büyüklüğü
10	ZEMIN_SALON	Oturulan konuttaki salonun zemin yapısı
11	ZEMIN_ODA	Oturulan konuttaki odaların zemin yapısı
12	ZEMIN_MUTFAK	Oturulan konuttaki mutfağın zemin yapısı
13	ZEMIN_BANYO	Oturulan konuttaki banyonun zemin yapısı
14	ISITMA_SISTEM	Konutun ısıtma sistemi
15	YAKIT_TUR_1	Konutta en çok kullanılan yakıt türü
16	YAKIT_TUR_2	Konutta en çok kullanılan ikinci yakıt türü
17	YAKIT_TUR_3	Konutta en çok kullanılan üçüncü yakıt türü

18	YAKIT_TUR_MUTFAK	Oturulan konutta yemek pişirmek amacıyla kullanılan temel yakıt türü
19	YAKIT_TUR_SICAKSU	Oturulan konutta sıcak su elde etmek amacıyla kullanılan temel yakıt türü
20	OLCEK_ALISVERIS	Konutun bulunduğu yer itibariyle “Günlük alışveriş” hizmetlerine kolayca ulaşabilme durumu
21	OLCEK_BANKACILIK	Konutun bulunduğu yer itibariyle “Bankacılık” hizmetlerine kolayca ulaşabilme durumu
22	OLCEK_POSTA	Konutun bulunduğu yer itibariyle “Posta” hizmetlerine kolayca ulaşabilme durumu
23	OLCEK_ULASIM	Konutun bulunduğu yer itibariyle “Toplu Ulaşım” hizmetlerine kolayca ulaşabilme durumu
24	OLCEK_SAGLIK_MERKEZI	Konutun bulunduğu yer itibariyle “Sağlık Merkezi” hizmetlerine kolayca ulaşabilme durumu
25	OLCEK_ZORUNLU_EGITIM	Konutun bulunduğu yer itibariyle “İlköğretim okulu” hizmetlerine kolayca ulaşabilme durumu

26	KONUT_IKINCI	İkinci konutun olup olmadığı
27	BANYO	Banyo sahipliği
28	SAUNA	Sauna sahipliği
29	JAKUZI	Jakuzi sahipliği
30	TUVALET	Tuvalet sahipliği
31	MUTFAK	Mutfak sahipliği
32	COP_OGUTUCU	Çöp öğütücü sahipliği
33	KALORIFER	Kalorifer sahipliği
34	TABAN_ISITMA	Tabandan ısıtma sahipliği
35	BORULU_SU_SISTEM	Borulu su sistemi sahipliği
36	DOGALGAZ	Doğalgaz sahipliği
37	SICAKSU	Sıcak su sahipliği
38	KABLO_YAYIN	Kablolu yayın sahipliği
39	ASANSOR	Asansör sahipliği
40	GARAJ	Garaj sahipliği
41	HAVUZ	Havuz sahipliği
42	JENERATOR	Jeneratör sahipliği
43	GUVENLIK_SISTEM	Güvenlik görevlisi/sistemi sahipliği
44	BALKON	Balkon sahipliği
45	BAHCE	Bahçe sahipliği
46	CEP_TELEFON_SAYI	Cep telefonu sayısı
47	BILGISAYAR_SAYI	Bilgisayar sayısı
48	INTERNET_SAYI	İnternet sayısı
49	PANEL_TV_SAYI	LCD veya PLAZMA televizyon sayısı
50	BUZDOLABI_SAYI	Buzdolabı sayısı
51	DERIN_DONDURUCU_SAYI	Derin dondurucu sayısı

52	BULASIK_MAKINE_SAYI	Bulaşık makinası sayısı
53	MIKRODALGA_FIRIN_SAYI	Mikrodalga fırın sayısı
54	CAMASIR_MAKINE_SAYI	Otomatik çamaşır makinası sayısı
55	CAMASIR_KURUTMA_SAYI	Çamaşır kurutma makinası sayısı
56	KLIMA_SAYI	Klima sayısı
57	OTOMOBIL_SAYI	Otomobil sayısı
58	ISVEREN_ARAC_SAYI	İşverence sağlanan ücretsiz araç sayısı
59	MOTOSIKLET_SAYI	Motosiklet sayısı
60	DENIZTASIT_SAYI	Motorlu-motorsuz deniz taşıtı sayısı
61	MUSKONUT_SAHİPLİĞİ	Müstakil konut sahipliği
62	MUSKONUT_MIKTAR	Sahip olunan müstakil konut miktarı
63	MUSKONUT_AYLIK_KIRA	Kiraya verilen müstakil konutun aylık toplam kira değeri
64	APARTMAN_SAHİPLİĞİ	Apartman dairesi sahipliği
65	APARTMAN_MIKTAR	Sahip olunan apartman dairesi miktarı
66	APARTMAN_AYLIK_KIRA	Kiraya verilen apartman dairesinin aylık toplam kira değeri
67	YAZLIK_SAHİPLİĞİ	Yazlık sahipliği
68	YAZLIK_MIKTAR	Sahip olunan yazlık miktarı
69	YAZLIK_AYLIK_KIRA	Kiraya verilen yazlığın (ların) aylık toplam kira değeri

<b>70</b>	TARLA_SAHİPLİĞİ	Tarla sahipliği
<b>71</b>	TARLA_MİKTAR	Sahip olunan tarla miktarı
<b>72</b>	TARLA_AYLIK_KIRA	Kiraya verilen tarlanın aylık toplam kira değeri
<b>73</b>	BAG_SAHİPLİĞİ	Bağ, bahçe sahipliği
<b>74</b>	BAG_MİKTAR	Sahip olunan bağ, bahçe miktarı
<b>75</b>	BAG_AYLIK_KIRA	Kiraya verilen bağ, bahçenin aylık toplam kira değeri
<b>76</b>	SERA_SAHİPLİĞİ	Sera sahipliği
<b>77</b>	SERA_MİKTAR	Sahip olunan sera miktarı
<b>78</b>	SERA_AYLIK_KIRA	Kiraya verilen sera aylık toplam kira değeri
<b>79</b>	ARSA_SAHİPLİĞİ	Arsa sahipliği
<b>80</b>	ARSA_MİKTAR	Sahip olunan arsa miktarı
<b>81</b>	ARSA_AYLIK_KIRA	Kiraya verilen arsa aylık toplam kira değeri
<b>82</b>	DUKKAN_SAHİPLİĞİ	Dükkan sahipliği
<b>83</b>	DUKKAN_MİKTAR	Sahip olunan dükkan miktarı
<b>84</b>	DUKKAN_AYLIK_KIRA	Kiraya verilen dükkanın(ların) aylık toplam kira değeri
<b>85</b>	ELEKTRİKLİ_BİSİKLET_SAYI	Elektrikli bisiklet sayısı
<b>86</b>	SIGARA_ALİSKANLIK	Hanede sigara, tütün, puro içme alışkanlığı olan fert olup olmadığı
<b>87</b>	ALKOL_ALİSKANLIK	Hanede alkollü içecek kullanma alışkanlığı olan fert olup olmadığı

88	DISARIDA_YEMEK	Hanede öğlen veya akşam yemeklerini dışarıda (lokanta, açık büfe, dönerci vb. yerlerde) yeme alışkanlığı olup olmadığı
89	UCRETLI_TV_ALISKANLIK	Hanede ücretli TV aboneliği (Digitürk, D-Smart vb.) olup olmadığı,
90	UCRETLI_SPOR_ALISKANLIK	Hanede ücret ödeyerek spor, eğlence, kültür vb. faaliyette bulunan fert olup olmadığı
91	OZEL_SIGORTA	Hanede özel yaşam sigortası olan fert olup olmadığı
92	KREDI_KARTI	Hanede kredi kartı kullanan fert olup olmadığı
93	PAZAR_ALISKANLIK	Hanede pazara gitme alışkanlığı olup olmadığı
94	INTERNET_ALISVERIS_SIKLIK	Hanede internetten alış-veriş yapma alışkanlığı olup olmadığı
95	TASARRUF_1	Hanede yapılan tasarrufları değerlendirme şekli - 1
96	TASARRUF_2	Hanede yapılan tasarrufları değerlendirme şekli - 2
97	TASARRUF_3	Hanede yapılan tasarrufları değerlendirme şekli - 3
98	TASARRUF_4	Hanede yapılan tasarrufları değerlendirme şekli - 4
99	HHB	Hanenin büyüklüğü

Bu işlemlerden sonra veri setinde 99 adet bağımsız, 1 adet bağımlı (hedef) değişkeni yer almaktadır. Çalışmada kullanılan tüm değişkenler açıklaması ile birlikte Tablo (3.2.1)'de gösterilmiştir.

TÜİK tarafından paylaşılan anket verileri yapılandırılmış veri olarak işlendiğinden tüm ön işleme adımlarına gerek duyulmamıştır. Sadece bazı eksik/kayıp verilerde medyan yöntemi ile doldurma gerçekleştirilmiştir. Medyan doldurma, bir veri kümesindeki eksik (ya da boş) değerleri veri kümesinin medyan değerine göre doldurma işlemidir (Nair vd., 2013). Bu işlem, veri kümesinde eksik değer olması durumunda yararlı olabilir, çünkü medyan doldurma, veri kümesinin ortalama değerini etkilemez ve bu nedenle veri kümesinin dağılımının anlamlı bir şekilde ölçülmesine yardımcı olmaktadır.

### **3.2.2. Yöntem**

Bu tezde belirlenen veri seti üzerinde öncelikle keşfedici veri analizi yapılmıştır. Daha sonra verilere istatistiksel analiz işlemleri, makine öğrenmesi algoritmaları ve yapay sinir ağları olmak üzere uygulamalar yapılmıştır. Araştırmanın problemi bir sınıflandırma tahminlemesidir. Sınıflandırma tahminlemesi, verilerin belirli bir sınıflandırma kategorisine göre etiketlenmesini veya tahmin etmeyi amaçlayan bir makine öğrenmesi tekniğidir. Bu teknik, verilerin özelliklerini ve etiketlerini analiz ederek, verilerin belirli bir kategoriye ait olduğunu tahmin etmek için kullanılmaktadır.

Makine öğrenmesi algoritmalarından 9 tanesi kullanılmıştır. Bu algoritmalar: Destek Vektör Makinesi, K En Yakın Komşu, Naive Bayes, Karar Ağacı, Rasgele Orman, XGBoost, LightGBM, Ada Boost, Gradyan Arttırma'dır. Yapay sinir ağı algoritmasından ise 1 tane kullanılmıştır. Bu algoritma Çok Katmanlı Algılayıcı (Multilayer Perceptron-MLP)'dir.

Makine öğrenmesi algoritmalarının sınıflandırma problemlerinde kullanılması ile veri setlerinde bulunan örnekleri kullanarak sınıflandırma yapılmakta ve yüksek doğruluk

oranları elde edilebilmektedir. Algoritmalar veri setlerinin boyutuna ve makine gücüne bağlı olarak hızlı tahmin yapabilmekte ve veriler üzerinde çalışarak, kendileri öğrenebilmektedir. Algoritmalar aracılığıyla büyük veri setleri üzerinde çalışılabilir ve güncel verilerle modellerin performansı arttırılabilmektedir. Ayrıca problemlerin veri setleri büyüdükçe veya daha fazla veri eklendiğinde ölçeklenebilir ve performansını koruyabilmektedir. Algoritmalar veri setindeki değişkenlerin etkisini analiz ederek en önemli değişkenleri seçebilmektedir. Bu durum daha az değişken ile daha doğru sonuçlara yönlendirilmesini sağlamaktadır. Bu avantajlar, makine öğrenmesi algoritmalarının sınıflandırma problemlerinde etkili bir şekilde kullanılmasını sağlamaktadır. Burada söz konusu edilen özellikler Özellik Önemliliği olarak işlenmiştir.

Yapay sinir ağları, girdiler ve çıktılar arasındaki doğrusal olmayan ilişkileri modelleyebilir ve bu da karmaşık veri dağılımlarını işleme yeteneği sağlar. Özellikle uygun regülasyon teknikleri ile birlikte, büyük ve karmaşık veri kümelerinde yüksek doğruluğa ulaşılabilmektedir. Bu ağla, ham verilerden anlamlı özellikler öğrenip çıkarabilmekte ve bu da manuel özellik mühendisliği gereksinimini azaltmaktadır.

Sinir ağları, büyük veri kümeleri ile iyi uyumlu ve dağıtık bir mimari üzerinde eğitilebilirler ve bu da daha fazla ölçeklenebilirlik sağlamaktadır. Yapay sinir ağları, görülmemiş verileri genelleştirme yeteneğine sahiptir ve eğitimlerine dayanarak tahmin yapabilir, bu da gerçek dünya uygulamalarında kullanışlı olmasına sebep olmaktadır.

Genel olarak, yapay sinir ağları, karmaşık doğrusal olmayan ilişkileri modelleme, büyük veri kümelerini işleme ve tahmin görevlerinde yüksek doğruluk sağlama yeteneği nedeniyle sınıflandırma problemlerinde yaygın olarak kullanılmaktadır.

Çalışma kapsamında tüm analizlerin Python programlama dili ile Spyder tümleşik geliştirme ortamında ve Google Colab ortamında yapılmıştır. Kullanılan Python kütüphaneleri: Pandas, NumPy, SciPy, Scikit-Learn, TensorFlow, Matplotlib, Seaborn'dur.



### 3.2.3. Analiz

Yoksulluk sınıflandırması, toplumda yaşayan bireylerin ekonomik durumlarını belirlemek ve sosyal politika yapıcılarına rehberlik etmek için kritik öneme sahiptir. Makine öğrenimi, bu tür sosyal sorunların çözümünde etkili bir araç olarak ortaya çıkmaktadır. Çalışma için kullanılan hanehalkı bütçe anketi verilerinden seçilen değişkenler, hanehalkının ekonomik durumunu temsil eden çeşitli özelliklerden oluşmakta iken bağımlı değişken ise hanehalkının yoksulluk durumunu göstermektedir. Bağımlı değişkende yer alan 2019 yılı için hesaplanan yıllık ortalama hanehalkı kullanılabilir geliri 51,873 Türk Lirası'ndan daha az olan bireylerin oranı %59,63 iken daha fazla olan bireylerin oranı ise %40,36'dır.

#### 3.2.3.1. Sınıflandırma Algoritmaları

Sınıflandırma algoritmaları eğitim süresi, doğruluk ve F1 skoru olmak üzere üç farklı metrik ile incelenmiştir: Eğitim süresi, her algoritmanın eğitim süresini saniye cinsinden göstermektedir. Daha düşük eğitim süresi, daha hızlı sonuçlar elde etmek anlamına gelmektedir. Ancak, bu süre, veri boyutu ve algoritmanın karmaşıklığına bağlı olarak değişebilmektedir. Doğruluk, her algoritmanın doğruluk oranını yüzde cinsinden ifade eder. Doğruluk, modelin tahminlerinin gerçek değerlere ne kadar yakın olduğunu göstermektedir. Yüksek doğruluk oranı, daha iyi bir model performansı anlamına gelir. Ancak doğruluk metriğini diğer metriklerle desteklemek daha iyi sonuçların elde edilmesini sağlar. Yapılan yoksulluk sınıflandırmasında F1 skoru tercih edilmiştir. F1 skoru, bir sınıflandırma modelinin doğruluğunu ölçen bir performans metriğidir. Hassasiyet (precision) ve geri çağırma (recall) değerlerinin harmonik ortalaması olarak hesaplanır. Hassasiyet, doğru pozitif tahminlerin toplam pozitif tahminlere oranını, geri çağırma ise gerçek pozitiflerin tüm gerçek pozitiflere oranını ifade eder. F1 skoru hem hassasiyeti hem de geri çağırma değerlerini dikkate alarak bir modelin performansını değerlendirerek dengeli bir sonuç sağlamaktadır. F1 skoru, sınıflar arasında dengesiz bir dağılım olduğunda tercih edilmektedir. Yoksulluk sınıflandırması gibi durumlarda, genellikle yoksulluk sınırının üstünde olan hanehalklarının oranı daha yüksek veya düşük olabilir, bu da sınıflar arasında dengesiz

bir dağılımı göstermektedir. F1 skoru yerine doğruluk (accuracy) metriği kullanıldığında model sadece çoğunluk sınıfını tahmin ederek yüksek bir doğruluk elde edebilir. Ancak F1 skoru, bu tür dengesizlikleri dikkate alarak modelin performansını daha doğru bir şekilde değerlendirmektedir.

Çalışmada Destek Vektör Makinesi, K-En Yakın Komşu, Naive Bayes (Gaussian), Karar Ağacı, Rasgele Orman, XGBoost, LightGBM, AdaBoost, Gradyan Arttırma ve Çok Katmanlı Algılayıcı (MLP) gibi çeşitli sınıflandırma algoritmaları kullanılmıştır. Her bir algoritma, eğitim süresi, doğruluk ve F1 skoru gibi performans metrikleri açısından değerlendirilmiştir.

**Tablo 3.2.2. Analiz sonucunda elde edilen sınıflandırma algoritmalarının başarıları ve karşılaştırmaları**

<b>Sınıflandırma Algoritmaları</b>	<b>Eğitim Süresi (saniye)</b>	<b>Doğruluk</b>	<b>F1 Skoru</b>
Destek Vektör Makinesi	0.00005	%67,8	%42,65
K-En Yakın Komşu	0.00004	%71,49	%62,30
Naive Bayes (Gaussian)	0.021	%66,37	%37,85
Karar Ağacı	0.22	%73,40	%67,06
Rasgele Orman	4.07	%79,65	%73,72
XGBoost	6.43	%81,77	%76,58
LightGBM	0.71	%82,47	%77,72
AdaBoost	1.15	%81,12	%76,53

Gradyan Arttırma	7.56	%81,77	%74,90
MLP	9.57	%70,32	%70,36

Tablo (3.2.2.)'da yer alan verilerin karşılaştırması ve incelenmesi aşağıda verilmiştir.

- Destek Vektör Makineleri (SVM)

Eğitim Süresi: 0.00005 saniye, Doğruluk: %67.8, F1 Skoru: %42.65

Genel Özellikler: SVM, doğrusal olmayan sınıflandırma problemlerinde etkili olan ve destek vektörleri adı verilen örnekler kullanarak karar sınırları oluşturan bir algoritmadır. Özellikle küçük veri setlerinde ve yüksek boyutlu verilerde etkili olmaktadır.

Performans Değerlendirmesi: SVM'in doğruluk ve F1 skoru düşüktür. Bunun nedeni, yoksulluk sınıflandırmasında veri setinin karmaşıklığı ve veri özelliklerinin doğrusal olmayan ilişkiler içermesi olabilir. Ayrıca, SVM'in belirli parametrisasyon gerektirmesi ve bu parametrelerin doğru ayarlanamaması da performansını olumsuz etkileyebilir.

- K-En Yakın Komşu (KNN)

Eğitim Süresi: 0.00004 saniye, Doğruluk: %71.49, F1 Skoru: %62.30

Genel Özellikler: KNN, sınıflandırma problemlerinde komşu veri noktalarının etiketlerine bakarak tahmin yapan basit ve sezgisel bir algoritmadır.

Performans Değerlendirmesi: KNN, hızlı eğitim süresi ve makul doğruluk oranı ile öne çıkmaktadır. KNN'in performansı, benzer yoksulluk seviyesine sahip bireylerin yakın veri noktalarında bulunmasıyla artar. Ancak, büyük veri setlerinde ve yüksek boyutlu verilerde KNN'in performansı düşebilir ve hesaplama maliyeti artabilir.

- Naive Bayes (Gaussian)

Eđitim Süresi: 0.021 saniye, Doğruluk: %66.37, F1 Skoru: %37.85

Genel Özellikler: Naive Bayes, sınıflandırma problemlerinde özelliklerin birbirinden bağımsız olduğunu varsayarak olasılık hesaplamaları yapan bir algoritmadır. Genellikle metin sınıflandırma gibi alanlarda kullanılır.

Performans Deđerlendirmesi: Naive Bayes'in düşük doğruluk ve F1 skoru, özellikler arasındaki bağımsızlık varsayımının yoksulluk sınıflandırması gibi karmaşık bir problemde geçerli olmamasından kaynaklanabilir.

- Karar Ağacı

Eđitim Süresi: 0.22 saniye, Doğruluk: %73.40, F1 Skoru: %67.06

Genel Özellikler: Karar Ağaçları, veri özelliklerine göre dallara ayrılan ve yapraklarda sınıflandırma yapan hiyerarşik modellerdir. Kolay anlaşılır ve yorumlanabilir modellerdir.

Performans Deđerlendirmesi: Karar Ağacı, iyi doğruluk ve F1 skoru ile makul performans sergilemektedir. Bunun nedeni, Karar Ağaçlarının veri içindeki karmaşık ilişkileri öğrenebilmesi ve her bir dalda belirli kararlar vererek esnek bir yapı sunmasıdır. Ancak, aşırı uyum (overfitting) riski bulunmaktadır ve bu durum performansı olumsuz etkileyebilir.

- Rasgele Orman

Eđitim Süresi: 4.07 saniye, Doğruluk: %79.65, F1 Skoru: %73.72

Genel Özellikler: Rasgele Orman, birden fazla karar ağacının bir araya gelerek oluşturduğu, topluluk öğrenme yöntemidir. Her ağaç rastgele seçilmiş alt özelliklerle eğitilir ve sonuçlar birleştirilir.

Performans Deęerlendirmesi: Rasgele Orman, yksek doęruluk ve F1 skoru ile olduka iyi bir performans sergilemektedir. Bunun nedeni, eřitli aęaların oy okluęuna dayalı karar vermesi ve bu sayede aşırı uyum riskinin azalmasıdır. Eęitim süresi uzun olmasına raęmen, modelin saęladığı yksek performans bu süreyi tolere edilebilir kılmaktadır.

- XG Boost

Eęitim Süresi: 6.43 saniye, Doęruluk: %81.77, F1 Skoru: %76.58

Genel Özellikler: XGBoost, gradyan artırma yöntemi kullanarak ardışık karar aęaları oluşturur ve her adımda hataları minimize eder. Bellek kullanımı ve hesaplama hızını optimize eden yenilikçi özellikler içerir.

Performans Deęerlendirmesi: XGBoost, yksek doęruluk ve F1 skoru ile mkemmel performans sergilemektedir. Bunun nedeni, gradyan artırma teknięi ile her aęacın hata payını azaltarak daha doęru tahminler yapabilmesidir. Eęitim süresi dięer algoritmalara göre uzun olmasına raęmen, saęladığı yksek performans nedeniyle bu süre göz ardı edilebilir.

- LightGBM

Eęitim Süresi: 0.71 saniye, Doęruluk: %82.47, F1 Skoru: %77.72

Genel Özellikler: LightGBM, büyük veri setlerinde hızlı ve etkin gradyan artırma algoritmasıdır. Daha az bellek kullanımı ve daha hızlı eęitim süresi ile öne çıkar. Özel olarak büyük veri setleri ve yksek boyutlu veriler için optimize edilmiştir.

Performans Deęerlendirmesi: LightGBM, en yksek doęruluk ve F1 skoru ile en iyi performansı sergilemektedir. Hızlı eęitim süresi ve düşük bellek kullanımı, yoksulluk sınıflandırması gibi büyük veri setlerinde avantaj sağlamaktadır. Ayrıca, LightGBM'in

veri içindeki karmaşık ilişkileri etkin şekilde öğrenebilmesi, yüksek performansının ana nedenidir.

- AdaBoost

Eğitim Süresi: 1.15 saniye, Doğruluk: %81.12, F1 Skoru: %76.53

Genel Özellikler: AdaBoost, zayıf sınıflandırıcıları (genellikle karar ağaçları) ardışık olarak uygulayarak hataları minimize eden bir topluluk yöntemidir. Her bir adımda ağırlıklı hatalar dikkate alınır ve model güncellenir.

Performans Değerlendirmesi: AdaBoost, yüksek doğruluk ve F1 skoru ile iyi bir performans göstermektedir. Bunun nedeni, zayıf sınıflandırıcıların hata oranlarını minimize ederek genel model performansını artırmasıdır. Eğitim süresi makul düzeyde olup, modelin sağladığı performans göz önüne alındığında tatmin edicidir.

- Gradyan Arttırma

Eğitim Süresi: 7.56 saniye, Doğruluk: %81.77, F1 Skoru: %74.90

Genel Özellikler: Gradyan Arttırma, ardışık modeller oluşturarak her adımda hata payını azaltan bir topluluk öğrenme yöntemidir. Her bir model bir öncekinin hatalarını düzeltmeye çalışır.

Performans Değerlendirmesi: Gradyan Arttırma, yüksek doğruluk ve F1 skoru sunmaktadır. Bunun nedeni, her adımda hata payını azaltarak daha doğru tahminler yapabilmesidir. Ancak, eğitim süresi oldukça uzundur ve bu durum, daha hızlı alternatifler bulunması durumunda dezavantaj yaratabilir.

- Çok Katmanlı Algılayıcı (MLP)

Eğitim Süresi: 9.57 saniye, Doğruluk: %70.32, F1 Skoru: %70.36

Genel Özellikler: MLP, derin öğrenme yöntemi olup, birden fazla gizli katman içeren sinir ağıdır. Nonlineer ilişkilere sahip verilerde güçlü performans gösterebilir.

Performans Değerlendirmesi: MLP, eğitim süresi en uzun olan algoritmadır. Doğruluk ve F1 skoru açısından orta düzeyde performans göstermektedir. Bu durum, veri setinin büyüklüğü ve karmaşıklığına bağlı olarak sinir ağlarının optimize edilmesinin zor olmasından kaynaklanabilir. Ayrıca, MLP'in aşırı uyum riski ve hiperparametre ayarlarının zorluğu da performansı olumsuz etkileyebilir.

- Eğitim Süresi ve Performans Karşılaştırması:

En hızlı algoritmalar Destek Vektör Makinesi (0.00005 saniye) ve K-En Yakın Komşu (0.00004 saniye) olarak görünmektedir.

En uzun eğitim süresi ise MLP (9.57 saniye) ve Gradyan Arttırma (7.56 saniye) algoritmalarında gözlenmiştir.

- Doğruluk Karşılaştırması:

En yüksek doğruluk oranı %82.47 ile LightGBM algoritmasında görülmektedir.

En düşük doğruluk oranı %66.37 ile Naive Bayes (Gaussian) algoritmasında gözlemlenmiştir.

- F1 Skoru Karşılaştırması:

En yüksek F1 skoru %77.72 ile LightGBM algoritmasında görülmektedir.

En düşük F1 skoru %37.85 ile Naive Bayes (Gaussian) algoritmasında gözlemlenmiştir.

- İnceleme:

LightGBM algoritması hem doğruluk hem de F1 skoru açısından en iyi performansı göstermektedir.

Eđitim süresi de makul seviyededir (0.71 saniye). XGBoost ve AdaBoost algoritmaları da yüksek doğruluk ve F1 skoru sunmaktadır, ancak eğitim süreleri daha uzundur.

Rasgele Orman algoritması, iyi performans ve kabul edilebilir eğitim süresi ile dengeli bir seçenektir.

K-En Yakın Komşu ve Karar Ağacı algoritmaları, daha hızlı eğitim süresi ile makul performans sergilemektedir.

MLP algoritması, daha uzun eğitim süresi ve ortalama doğruluk ile diğer algoritmalara kıyasla daha düşük performans göstermektedir.

Naive Bayes (Gaussian) ve Destek Vektör Makinesi, en düşük doğruluk ve F1 skorları ile dikkat çekmektedir.

Elde edilen bulgulara göre, LightGBM algoritması en yüksek doğruluk ve F1 skoruna sahiptir (%82,47 doğruluk, %77,72 F1 skoru). Ardından XGBoost ve Rasgele Orman algoritmaları gelmektedir. En düşük performansı ise Naive Bayes (Gaussian) algoritması göstermektedir.

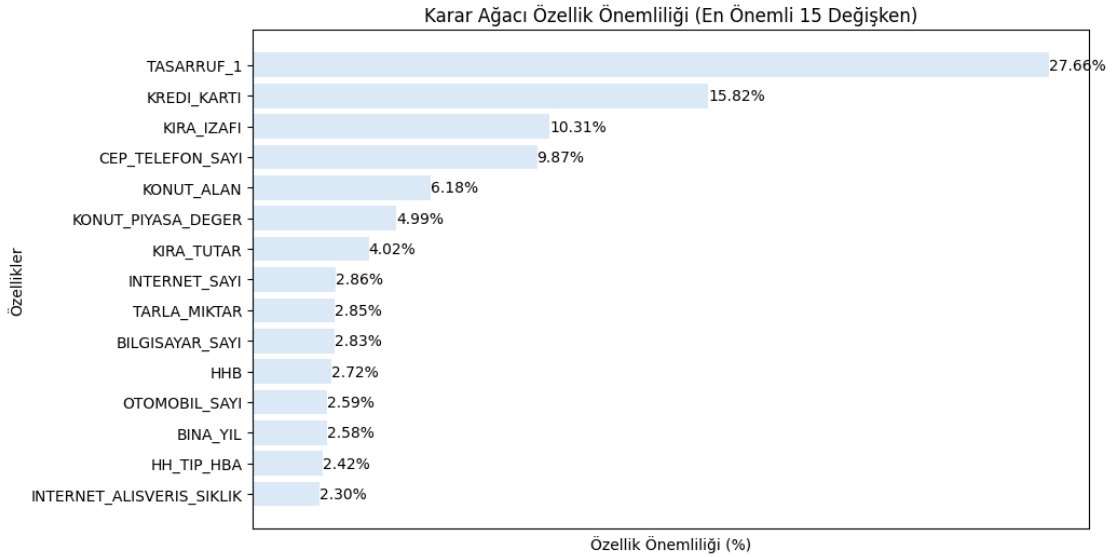
Algoritmaların eğitim süreleri arasında önemli farklılıklar gözlemlenmiştir. Destek Vektör Makinesi ve K-En Yakın Komşu algoritmaları, en kısa eğitim süresine sahipken, MLP ve Gradyan Arttırma algoritmaları en uzun eğitim sürelerine sahiptir. Veri sayısının ve değişken sayısının fazlalığı göz önünde bulundurulduğunda; eğitim sürelerinin saniyeler içerisinde gerçekleşmesi, yoksulluk sınıflandırmasında yapay zekanın uygulanabilirliğine dikkat çekmektedir.

Sonuçlar, Gradyan Arttırma temelli algoritmaların yoksulluk sınıflandırmasında diğerlerine göre daha etkili olduğunu göstermektedir. Bu algoritmalar, veri setindeki karmaşık ilişkileri daha iyi yakalayarak, daha yüksek doğrulukla sınıflandırma yapabilmektedir. Bununla birlikte, eğitim sürelerinin de göz önünde bulundurulması gerekmektedir. Özellikle büyük veri setlerinde hızlı eğitim süreleri, modelin pratik uygulamalarda kullanılabilirliğini artırmaktadır.

### 3.2.3.2. Özellik Önemliliği

Özellik önemliliği, makine öğrenmesi modellerinde her bir özelliğin (veya değişkenin) modelin çıktısına katkısını ölçen bir tekniktir. Bu analiz, hangi özelliklerin modelin tahminlerinde en etkili olduğunu belirlemeye yardımcı olur ve böylece modelin anlaşılabilirliğini ve performansını artırır. Her bir makine öğrenimi algoritmasının özellik önemliliği grafikleri, yoksulluk tahminlemesi ve sınıflandırması üzerindeki performansını artıran kritik değişkenleri belirlemek için önemlidir. Bu özellikler, yoksulluk tahminlemesi ve sınıflandırması için kritik rol oynar ve model seçimi yaparken dikkate alınması gereken temel faktörlerdir. Yapılan analizler, makine öğrenimi algoritmalarının yoksulluk sınıflandırması gibi karmaşık sosyal problemler için nasıl kullanılabilirliği ve hangi özelliklere odaklanması gerektiği konusunda önemli bilgiler sunmaktadır.

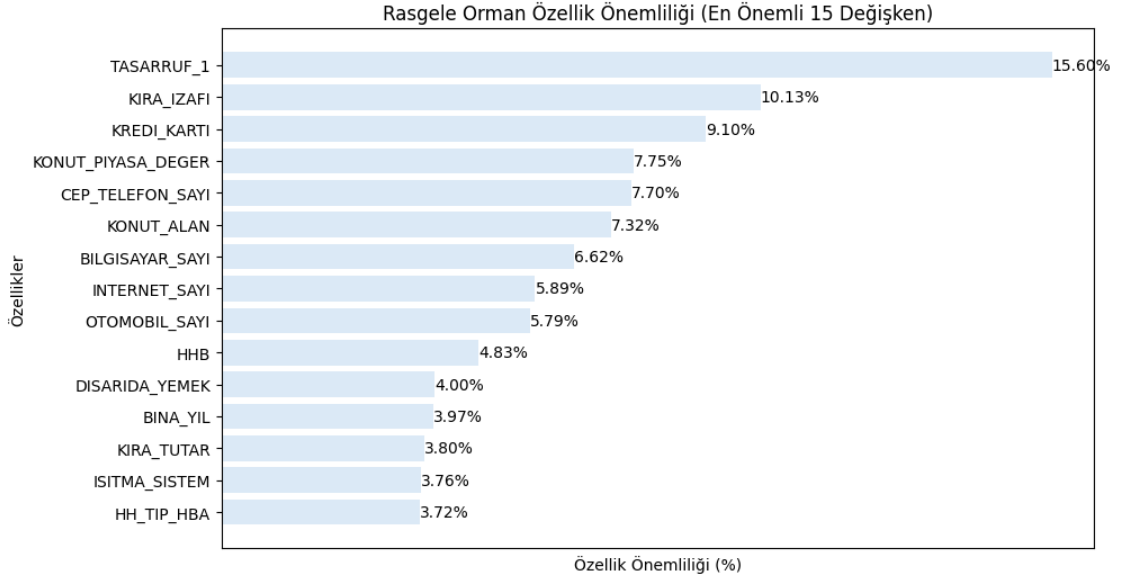
#### Şekil 3.2.1. Karar Ağacı Özellik Önemliliği



Karar ağaçları, veri setindeki karar kurallarını öğrenirken hangi özelliklerin daha belirleyici olduğunu öğrenir ve bu kurallara göre sınıflandırma yapar. Karar kurallarını oluşturan özelliklere göre önemlilik derecelerini atamaktadır. Bu modelde, TASARRUF\_1 şeklinde adlandırılmış, hanede yapılan tasarrufları değerlendirme şekli


-1 deęişkeni yüksek önemlilik göstermektedir. Bu deęişkende tasarruflar; gayrimenkul (ev, dükkan, arsa, tarla, vb), konut kooperatif üyelięi, altın, döviz, banka hesabı, hisse senedi, tahvil, bono, fon katılım belgesi, işe yapılan yatırımlar, faiz ile borç para vermek veya tasarruf yapmıyor şeklinde sınıflandırılmış olup karar kurallarının oluşturulmasında ve sınıfların ayrıştırılmasında kritik rol oynamaktadır. Hanede yapılan tasarruf şeklini takip eden sırada, KREDI\_KARTI şeklinde adlandırılmış, hanede kredi kartı kullanan fert olup olmadığını ölçen deęişken yer almaktadır. Bu deęişken özellięi bakımından ağaçlarda sık sık kritik bölünmelere neden olduğu için özellik önemlilięi yüksektir. Kredi kartı kullanımı, hanelerin harcama alışkanlıkları ve finansal yönetim becerileri hakkında bilgi vermesi bakımından önem taşımaktadır. Üçüncü sırada yer alan, KIRA\_IZAFI şeklinde adlandırılan, aylık izafi kira deęişkeni anket ayındaki piyasa koşullarında aynı bölgede benzer bir konutun kiralınması durumunda ödenmesi gereken aylık kira deęeridir. Belirli bir bölgedeki genel kira fiyatları, konutun bulunduğu semt veya mahalleye göre deęişmektedir. Aynı bölgedeki benzer konutlar arasındaki kira farklılıkları, bölgenin sosyo-ekonomik durumu, ulaşım olanakları, okullar ve dięer hizmetlere olan yakınlık gibi faktörlere baęlıdır. Bu deęişken, barınma maliyetlerini, ekonomik yükü ve bölgesel sosyo-ekonomik koşulları yansıtarak, hanehalkının yoksulluk sınıfını belirlemede kritik bir gösterge sağlamaktadır.

### Şekil 3.2.2. Rasgele Orman Özellik Önemliliği




Rasgele Orman algoritmasında da tıpkı karar ağacı algoritmasında hesaplandığı gibi ilk üç değişken aynı seyretmektedir. Bu değişkenleri takip eden sırada, birbirine çok yakın yüzdelerde bulunan KONUT\_PİYASA\_DEGER ve CEP\_TELEFONU\_SAYISI şeklinde adlandırılan, hanelere oturdukları konutun anket ayı piyasa koşullarındaki satış fiyatının ne olacağı sorularak TL cinsinden değeri kayıt edilen konut piyasa değeri ve hanede bulunan toplam cep telefonu sayısı izlemektedir. Yüksek piyasa değerine sahip konutlar, genellikle daha düşük yoksulluk riski ile ilişkilidir. Çok sayıda cep telefonu, hanehalkının teknolojik erişim ve bilgiye ulaşma yeteneğini gösterir. Bu da hanehalkının maddi durumunun iyi olduğunu ve düşük yoksulluk riski taşıdığını göstermektedir.

### Şekil 3.2.3. Gradyan Arttırma Özellik Önemliliği




Gradyan Arttırma yöntemi, makine öğrenmesi uygulamalarında yüksek performanslı modeller oluşturmak için kullanılan etkili bir tekniktir. Bu yöntem, ardışık olarak zayıf öğrenciler (genellikle karar ağaçları) ekleyerek ve her bir adımda hataları minimize ederek güçlü bir tahmin modeli oluşturmaktadır. Gradyan Arttırma metodunda özellik önemliliği, modelin tahmin performansını ne ölçüde etkilediğini belirlemek için kullanılmaktadır. Bir özelliğin önemliliği, modelin karar ağacında o özelliğin bölünme noktası olarak ne kadar sıklıkla kullanıldığı ve bu kullanımların modelin hata oranını ne kadar azalttığı ile ilişkilidir. Bu yöntemde, TASARRUF\_1, KREDI\_KARTI, BILGISAYAR\_SAYI şeklinde adlandırılan, hanede yapılan tasarruf şekli, hanede kredi kartı kullanan fert olup olmadığını ölçen değişken ve hanede bulunan bilgisayar sayısı yoksulluk sınıflandırmasını etkileyen en önemli üç değişken olarak gözlenmektedir. Bu değişkenlerin her biri, hanehalkının finansal güvenliği, temel ihtiyaçlara erişim ve eğitim fırsatlarına erişim gibi kritik faktörlerle doğrudan ilişkilidir.

### Şekil 3.2.4. XGBoost Özellik Önemliliği




XGBoost (Extreme Gradient Boosting), yüksek performanslı ve esnek bir makine öğrenmesi algoritmasıdır. Temel olarak, bir dizi zayıf öğrenici olan karar ağaçlarını kullanarak güçlü bir model oluşturur. Bu model, özellikle sınıflandırma ve regresyon görevlerinde yüksek doğruluk sağlar. XGBoost modeli değişken olarak Gradyan Arttırma modeli ile yapısı gereği benzerlik gösterse de KREDI\_KARTI şeklinde adlandırılan hanede kredi kartı kullanan fert olup olmadığını ölçen değişken diğer özelliklere göre daha çok öne çıkmaktadır. XGBoost modelinin sınıflandırma başarısı dikkate alındığında; bir hanede kredi kartı kullanımı hane gelirinin düzenliliğini ve ekonomik istikrarı göstermektedir. Kredi kartı olmayan haneler genellikle daha düzensiz ve düşük gelir seviyesine sahip olmaktadır. Aynı zamanda kredi kartı kullanımı, bireylerin finansal okuryazarlığı ve planlama yapabilme yeteneğini de göstermektedir. Finansal planlama ise yoksulluktan kaçınmada önemli bir faktördür.

### Şekil 3.2.5. AdaBoost Özellik Önemliliği



AdaBoost metodu toplu öğrenme yöntemlerinden biridir ve zayıf öğrencileri (genellikle karar ağaçları) bir araya getirerek güçlü bir öğrenci oluşturmayı amaçlamaktadır. Bu doğrultuda her yeni modelin önceki modellerin hatalarını düzeltmeye çalıştığı iteratif bir süreç kullanılmaktadır. Diğer modellerde olduğu gibi hanede bulunan toplam cep telefonu sayısı ve izafi kira değişkenleri üst sıralarda yer almaktadır. Ancak üçüncü sırada HH\_TIP\_HBA şeklinde adlandırılmış hanehalkı tipi değişkeni (Tek kişilik hanehalkı, sadece eşlerden oluşan çekirdek aile, eşler ve çocuklardan oluşan çekirdek aile, tek ebeveyn ve çocuklardan oluşan çekirdek aile, en az bir çekirdek aile ve diğer kişilerden oluşan hanehalkı, çekirdek aile bulunmayan birden fazla kişiden oluşan hanehalkı düzeyleri bulunmaktadır.) özellik önemliliğinde dikkat çekmektedir. Hanehalkı tipi; gelir dağılımı, çalışma durumu, sosyal destek ve güvenlik açısından yoksulluğu etkileyen önemli bir faktördür.

**Şekil 3.2.6. LightGBM Özellik Önemliliği**



LightGBM, makine öğrenimi ve özellikle sınıflandırma problemlerinde yaygın olarak kullanılan güçlü bir algoritmadır. Bu algoritma, büyük veri setleri ve yüksek boyutlu veri problemleri için tasarlanmış olup, hız ve doğruluk açısından önemli avantajlar sunmaktadır. Özellik önemliliği analizi yapıldığında yoksulluk sınıflandırmasında önemli bulunan ilk üç değişken; KIRA\_IZAFI, KONUT\_ALAN ve KONUT\_PİYASA\_DEGER şeklinde adlandırılmış, aylık izafi kira değişkeni, hanenin yaşadığı konutun metrekare cinsinden alanı ve konutun piyasada gerçekleşecek satış değeri olduğu tespit edilmiştir. Yoksulluk düzeyini belirlemede kritik bir rol oynayan izafi kiranın yüksek olması, gelirin büyük bir kısmının konut masraflarına harcandığını göstermektedir. Bu durum, hanenin diğer temel ihtiyaçlarını karşılamada zorluk çekmesine neden olmakta ve dolayısıyla yoksulluk riskini de arttırmaktadır. Konut alanı, bir evin fiziksel büyüklüğünü ifade eder ve genellikle yaşam kalitesi ile doğrudan ilişkilidir (Chris, 2016). Konut piyasa değeri ise bir konutun mevcut piyasa koşullarındaki tahmini değerini ifade etmektedir. Yüksek piyasa değeri olan bir konut, genellikle daha varlıklı bireyler tarafından sahip olunan veya kiralanan bir konut olabilir. Düşük piyasa değeri ise, daha düşük gelirli bireylerin yaşadığı bölgeleri işaret edebilir. Bu nedenle, konut piyasa değeri de yoksulluk düzeyini belirlemede kritik bir

rol oynar. LightGBM'nin bu deęişkeni önemli olarak tanımlaması, ekonomik durumun ve mülk deęerinin yoksulluk üzerinde ne kadar etkili olduğunu göstermektedir.

LightGBM algoritması, bu üç deęişkeni en önemli olarak belirleyerek, yoksulluk sınıflandırmasında temel faktörlerin konutla ilgili maliyetler ve özellikler olduğunu ortaya koymaktadır. İzafi kira, konutun alanı ve piyasa deęeri gibi deęişkenler, bireylerin ekonomik durumu ve yaşam kalitesi hakkında doğrudan bilgi verir. Yapılan analizler neticesinde; araştırmaya konu olan hanehalkı yoksulluk düzeyinin hanelerin özellikleri bakımından incelenmesinde en başarılı bulunan algoritma LightGBM metodur. Bu bilgiler, yoksulluk düzeyini belirlerken ve uygun politikalar geliştirirken kritik öneme sahiptir.

## SONUÇ

Yoksulluk, dünya çapında milyonlarca insanı etkileyen karmaşık bir sorundur. Genellikle gelir ve temel kaynakların eksikliği ile ilişkilendirilen yoksulluk, literatürde ekonomik terimlerle tanımlanmakta ve anlaşılmaya çalışılmaktadır. Buna göre en genel anlatımla yoksulluk, bireylerin veya hanelerin temel ihtiyaçlarını karşılayamaması veya kabul edilebilir bir yaşam standardına ulaşamaması durumunu ifade etmektedir. Yoksulluk ölçümleri ise temel olarak gelir, tüketim ve servet gibi çeşitli göstergeler kullanılarak ölçülürken bireylerin veya hanelerin yoksul kabul edildiği bir eşiği temsil eden yoksulluk çizgisi gibi kavramlar ise yoksulluğu belirlemek için ele alınan önemli ölçütler arasında yer almaktadır. Bununla birlikte yoksulluğun statik bir kavram olmadığını ve konum, kültürel normlar ve kamu politikaları gibi çeşitli faktörlere bağlı olarak değişebileceği ileri sürülebilir.

Gelir, yoksulluğun belirlenmesinde rol oynayan en önemli faktör olarak değerlendirilebilir. Örneğin Dünya Bankası, aşırı yoksulluğu günde 1.90 doların altında yaşamak olarak tanımlamakta ve yoksulluğu azaltmayı amaçlayan politika yapımcılar ve uluslararası örgütler için bir referans noktası olarak hizmet etmektedir. Ancak, yoksulluğun yalnızca gelirle sınırlı olmadığını ve eğitime, sağlık hizmetlerine ve istihdam fırsatlarına erişim gibi faktörleri de içerdiğini belirtmek önemlidir. Tüketim, yoksulluk ölçümünde kullanılan bir diğer önemli unsurdur. Bireylerin veya hanelerin fiili olarak tükettiği mal ve hizmetlerin ölçülmesi yoluyla belirlenen yoksulluk düzeyi söz konusu kimselerin yaşadığı sorunları tespit etme açısından önemli bilgiler sağlamaktadır. Buna göre yoksulluk, gıda, barınma ve sağlık hizmetleri gibi temel mal ve hizmetlere sınırlı erişime yol açarak yoksulluğun şiddetini de etkilemektedir. Üçüncü olarak servet, mülk, yatırım ve finansal kaynaklar gibi varlıkların birikimini ifade etmekte ve bireylerin daha yüksek bir yaşam standardına sahip olmalarını sağlamaktadır. Yoksulluk ise servet ve gelir arasındaki ters ilişkiyi yansıtır ve bireylerin ve hanelerin sınırlı varlıklara ve mali kaynaklara sahip olduğu durumu ifade etmektedir.

Yoksulluk hem bireyler hem de toplum üzerinde geniş kapsamlı sonuçlar doğurmaktadır. Bu bağlamda eşitsizliklerin sürmesine, üretkenliğin azalmasına ve ekonomik büyüme ve kalkınmanın engellenmesine yol açan yoksulluğun eğitim eksikliği, sağlık hizmetlerine sınırlı erişim, ayrımcılık ve istihdam fırsatlarına sınırlı erişim gibi çeşitli faktörler üzerinden analiz edilmesi, başta politika yapıcılar olmak üzere yoksullukla mücadelede yer alan tüm aktörlere önemli ve faydalı bilgiler sağlamaktadır. Yoksulluğa katkıda bulunan sosyoekonomik faktörler, eğitim, sağlık hizmetleri, kaynaklara erişim ve ayrımcılık gibi çeşitli faktörler hakkında bilgi sağlayan çalışmalar literatürde yoğun olarak görülmektedir. Dolayısıyla yoksulluğu ekonomik terimlerle anlamak, yoksulluğu azaltmak ve yaşam standartlarını iyileştirmek için etkili politikalar ve programlar geliştirmek için önemlidir.

Yoksulluk araştırmaları, toplum içindeki kırılgan grupların belirlenmesi bakımından da önem arz etmektedir. Yaş, cinsiyet, etnik köken ve engellilik durumu gibi farklı demografik faktörlerin incelenmesi yoluyla, yoksulluk içinde yaşama olasılığı daha yüksek olan belirli popülasyonların tanımlanması amaçlanmaktadır. Bu bilgi, kaynakları, politikaları ve programları en çok ihtiyaç duyanlara yönlendirmek ve hizmetlere ve fırsatlara adil erişimi sağlamak için esas teşkil etmektedir. Bu bağlamda düzenli olarak veri toplama, sonuçları analiz etme ve gerektiğinde düzenlemeler yapmak suretiyle, araştırmacılar müdahalelerin etkinliğini değerlendirebilir ve iyileştirme alanlarını belirleyebilirler.

Literatürde araştırmacılar genellikle anlamlı sonuçlar elde edebilmek için gelişmiş analitik tekniklerin kullanılmasını gerektiren karmaşık veri setleriyle karşılaşmaktadır. Son yıllarda ise literatürde ekonomik değişkenleri tahmin etmek, piyasa trendlerini öngörmek ve ekonomik davranışları simüle etmek için makine öğrenimi ve yapay sinir ağları gibi modeller, araştırmacıların ilgisini çekmektedir. Makine öğrenimi, bilgisayarların verilerden öğrenmesini ve açık bir programlama olmaksızın tahminler veya kararlar almasını sağlayan bir yapay zekâ dalıdır. Geleneksel istatistiksel yöntemlerin aksine, makine öğrenimi teknikleri, araştırmacının hipotezleri veya

fonksiyonel formları belirtmesini gerektirmemektedir. Bunun yerine, bilgisayar verilerden desenler öğrenmekte ve bu desenlere dayalı çıkarımlar veya tahminler yapmaktadır. Bu bağlamda denetimli ve denetimsiz öğrenme gibi yöntemlerle elde edilen algoritmalar veri setlerine uygulanarak gizli yapıları veya ilişkileri ortaya çıkarabilmektedir.

Yapay sinir ağları ise insan beyninin yapısı ve işlevinden esinlenen hesaplamalı modeller olarak tanımlanmaktadır. Buna göre yapay sinir ağları girdi alarak, birleştirerek ve dönüştürerek bilgi işleyen birbirine bağlı yapay nöronlardan oluşmakta ve ekonomik tahmin, duygu analizi ve duygu sınıflandırması gibi çeşitli görevlerde kullanılmaktadır.

Geleneksel olarak, yoksulluk değerlendirmeleri öznel anketler ve istatistiksel modellere dayanırken makine öğrenimi ve yapay zekâ alanındaki teknolojik ilerlemeler, alternatif yöntemlerle yoksulluk tahmini için yeni yaklaşımları mümkün kılmıştır. Buna göre makine öğrenimi algoritmaları, çeşitli veri kaynaklarını analiz ederek yoksulluk tahminlerinde kullanılabilir. Makine öğrenimi algoritmalarını uygulamadan önce, veri kümesinin işlenerek temizlenmesi gerekmektedir. Bu durum, eksik değerleri kaldırmayı, değişkenleri sayısal özelliklere dönüştürmeyi ve yoksulluğu etkileyen ilgili değişkenleri tanımlamayı kapsamaktadır.

Makine öğrenimi ve yapay sinir ağları, hane yoksulluğu seviyesini tahmin etmede büyük potansiyele sahiptir. Bu teknikler büyük ölçekli veri setlerine uygulandığında, politika yapıcılar yoksulluk dinamikleri hakkında değerli bilgiler elde edebilir ve müdahaleleri daha etkili bir şekilde hedefleyebilirler. Ancak, bu yöntemlerin sınırlamalarını, eğitim verilerindeki olası yanlılıkları ve aşırı uyum riskini dikkate almak önemlidir. Ayrıca, verilerin erişilebilirliği ve kalitesi, yoksulluk tahmin modellerinin performansını da önemli ölçüde etkileyebilmektedir.

Çalışma, Türkiye’de hanehalkı yoksulluk düzeylerini tahmin etmek için makine öğrenimi ve yapay sinir ağlarını kullanarak Türkiye özelinde model performansı ve

yorumlanabilirliğini iyileştirmede önem analizini konu edinmektedir. Bu bağlamda Türkiye'de hanehalkı yoksulluk düzeyinin tahmininde kullanılan makine öğrenmesi modelleri aşağıdaki gibidir:

1. Karar Destek Makinesi (SVM)
2. K En Yakın Komşu (KNN)
3. Naive Bayes (Gaussian)
4. Karar Ağacı
5. Rasgele Orman
6. XGBoost
7. LightGBM
8. Ada Boost
9. Gradyan Arttırma
10. Çok Katmanlı Algılayıcı (Multilayer perceptron-MLP)

Söz konusu modeller arasında performans karşılaştırması yapılmış ve aşağıdaki sonuçlar elde edilmiştir:

- I. LightGBM: Hem doğruluk hem de F1 skoru açısından en iyi performansı göstermiştir. Ayrıca, eğitim süresi de oldukça makul düzeydedir.
- II. XGBoost ve AdaBoost: Yüksek performans göstermiş, ancak eğitim süreleri daha uzundur. Rasgele Orman, Karar Ağacı ve KNN: Makul performans sergilemiştir.
- III. Naive Bayes ve SVM: Düşük performansları nedeniyle yoksulluk sınıflandırması için uygun seçenekler değildir.

Özellik önemliliği analizi, makine öğrenmesi ve yapay sinir ağları yöntemlerinin yoksulluk tahminindeki başarısını artırmada ve yorumlanabilirliğini sağlamada kritik bir rol oynamaktadır. Bu analiz, her bir özelliğin (veya değişkenin) modelin çıktısına katkısını ölçer ve hangi özelliklerin modelin tahminlerinde en etkili olduğunu

belirlemeye yardımcı olmaktadır. Bu bağlamda özellik önemliliği analizinin yoksulluk tahminindeki rolü aşağıdaki gibi özetlenebilir:

- I. Performans Artırma: Özellik önemliliği analizi, modelin performansını artırmada önemli bir araçtır. En etkili özellikleri belirleyerek, bu özellikler üzerinde daha fazla odaklanabilir veya daha az etkili özellikleri eleyebilir. Bu sayede, modelin doğruluğu ve genellenebilirliği artırılabilir.
- II. Yorumlanabilirlik: Özellik önemliliği analizi, modellerin nasıl çalıştığını anlamak için önemlidir. Hangi özelliklerin en çok etkili olduğunu bilmek, yoksulluk tahminlerindeki kararları daha iyi yorumlamak için yardımcı olur. Bu da politika yapıcılara ve diğer karar vericilere, modelin çıktısına güven duymaları için gerekli bilgiyi sağlamaktadır.
- III. Model Seçimi: Özellik önemliliği analizi, farklı makine öğrenmesi algoritmaları ve yapay sinir ağları modelinin performansını karşılaştırmak için kullanılabilir. Bu analiz, hangi özelliklerin en iyi sonuçları verdiğini göstererek, en uygun modelin seçimine yardımcı olmaktadır.
- IV. Veri Kalitesi ve Hazırlığı: Özellik önemliliği analizi, veri kalitesini ve hazırlığını iyileştirmek için de kullanılabilir. Örneğin, düşük önemli özelliklerin veri setinden çıkarılması, modelin işleme hızını artırabilir veya veri toplama maliyetlerini azaltabilir.
- V. Risk ve Güven Yönetimi: Özellik önemliliği analizi, yoksulluk tahminindeki riskleri ve güveni yönetmek için de kullanılabilir. En etkili özellikleri bilmek, riskleri daha iyi anlayıp yönetmek için gerekli bilgiyi sağlar ve güven düzeyini artırır.

Bu bağlamda özellik önemliliği analizi, yoksulluk tahmininde kullanılan makine öğrenmesi ve yapay sinir ağları yöntemlerinin başarısını artırmada ve yorumlanabilirliğini sağlamada kritik bir role sahiptir. Bu analiz, modelin performansını artırmak, yorumlanabilirliğini sağlamak, en uygun modeli seçmek, veri

kalitesini ve hazırlığını iyileştirmek ve risk ve güven yönetimini desteklemek için önemli bir araçtır.

Çalışmada farklı makine öğrenimi algoritmalarının ve Çok Katmanlı Algılayıcı'nın yoksulluk sınıflandırması üzerindeki performansları da karşılaştırılmıştır. LightGBM, hem doğruluk hem de F1 skoru açısından en iyi performansı gösterirken, eğitim süresi de oldukça makuldür. Bu sonuçlar, yoksulluk sınıflandırması için en uygun algoritmanın LightGBM olduğunu göstermektedir. XGBoost ve AdaBoost da yüksek performans göstermekte, ancak eğitim süreleri daha uzun sürmektedir. Rasgele Orman, Karar Ağacı ve KNN de makul performanslar sergilemektedir. Naive Bayes ve SVM ise düşük performansları nedeniyle yoksulluk sınıflandırması için uygun seçenekler değildir. Bu değerlendirmeler, makine öğrenimi algoritmalarının yoksulluk sınıflandırması gibi karmaşık problemler için nasıl seçilmesi gerektiği konusunda önemli bilgiler sunmaktadır. Bu süreçte, özellik önemliliği analizi, modellerin performansını artırmada ve yorumlanabilirliğini sağlamada kritik bir rol oynar. Araştırmada seçilen algoritmaların özellik önemliliği incelendiğinde; en sık tekrar eden özelliğin izafi kira olduğu görülmektedir. Aylık izafi kira değişkeni anket ayındaki piyasa koşullarında aynı bölgede benzer bir konutun kiralanması durumunda ödenmesi gereken aylık kira değeridir. Bu özelliği takip eden sırada sık tekrar eden özellikler ise hanede yapılan tasarrufları değerlendirme şekli -1 değişkeni ve hanede kredi kartı kullanan fert olup olmadığını ölçen değişkendir. İzafi kira, piyasa koşullarına göre konut maliyetinin yoksulluk durumunun önemli bir göstergesi olduğunu göstermektedir. Daha yüksek nispi kira, hanehalkları üzerinde daha büyük bir mali yük ile ilişkilendirilebilir ve potansiyel olarak onları yoksulluğa itebilir. Hanehalkı tasarruflarını kullanma şekli, hanehalklarının tasarruflarını kullanma biçimlerinin yoksulluk durumlarını belirlemede kilit bir rol oynadığına işaret etmektedir. Belirli tasarruf davranışları finansal istikrar veya istikrarsızlık ile güçlü bir şekilde ilişkili olabilmektedir. Hanede bir kredi kartı kullanıcısının bulunması, finansal dayanıklılıkla bağlantılı olabilecek kredi olanaklarına erişimi gösterebilir. Tersine, kullanım bağlamına bağlı olarak borç anlamına da gelebilmektedir. Özellik önemliliği

analizi 2019 yılı verilerine göre incelenen nüfus içindeki yoksulluğu anlama ve tahmin etmede çok önemli faktörlerin yer aldığını göstermektedir. Bu bilgiler, konut sübvansiyonları, tasarruf programları ve kredi yönetimi eğitimi gibi yoksulluğu azaltmaya yönelik hedefli müdahalelere ve politika kararlarına rehberlik edebilir.

TÜİK'in 2023 yılında açıkladığı Hanehalkı Bütçe Araştırması'na göre; Türkiye genelinde hanehalklarının tüketim amaçlı yaptığı harcamalar içinde en yüksek payı %23,9 ile konut ve kira harcamalarının aldığını belirtilmiştir (TÜİK, 2023). Bu durum; çalışmada yapay zekâ aracılığıyla yapılan analizde, özellik önemliliği bakımından üst sıralarda yer alan aylık izafi kira değişkenini destekler niteliktedir. Canbay ve Selim (2010) klasik bir model (logit) uyguladıkları çalışmalarında yoksulluğu etkileyen önemli faktörlerden birinin kentsel kesimde hanehalkı büyüklüğünün olduğunu tespit etmiştir. Çalışmada yüksek performans gösteren bir diğer makine öğrenmesi modeli olan AdaBoost modelinde gerçekleştirilen analiz neticesinde 99 bağımsız değişken arasından en önemli üçüncü değişken olarak hanehalkının büyüklüğü (tipi) yer almaktadır. Topal ve Akay (2020) araştırmalarında 2018 yılına ilişkin Hanehalkı Bütçe Anketi üzerinden uyguladıkları klasik ve modern yöntemler neticesinde hanehalkının tüketim harcamalarını önemli düzeyde etkileyen değişkenler ile yoksulluk sınıflandırmasının yapay zekâ aracılığı ile yapıldığı bu çalışmada benzer sonuçlar yer almaktadır. Tüketim harcamalarında büyük pay edinen tasarruf, hanehalkı büyüklüğünü ve kredi kartı kullanımı değişkenleri, yoksulluk sınıflandırmasında bir neden olabilmektedir. Literatür incelendiğinde; hanehalkı yoksulluk düzeyinin hane bazında tahmininde makine öğrenmesi yöntemlerinden LightGBM modeli ile başarı sağlamış bir araştırmanın yer almadığı görülmektedir. Dolayısıyla bu çalışmanın daha sonra yapılacak araştırmalar için bir yol gösterici niteliğe sahip olduğu düşünülmektedir.

Çalışmada veri, metodoloji, analiz ve yoksulluk ölçümüne ilişkin çeşitli kısıtlar bulunmaktadır. Çalışmada kullanılan hanehalkı bütçe anketi verilerinde, Türkiye genelinde %25,9 oranında sorulara cevap vermeme durumu gerçekleşmiştir. Bu durum, veri setinin tamamının değil, sadece yanıt veren hanelerin verilerini temsil ettiğini göstermektedir. Bununla birlikte anket verilerinde, ortalama hane yapısını ciddi derecede etkileyecek ve modelin sapmasını artıracak değişkenler (örneğin, sera ve otel sahipliği, çöp öğütücü sahipliği, telefon hattı sayısı) kapsam dışı bırakılmıştır. Bu kısıtlama, modelin genellenebilirliğini ve doğruluğunu etkilemiş olabilir.

Çalışmada kullanılan makine öğrenmesi modellerinin her biri kendi sınırlamalarına sahiptir. Örneğin, karar ağaçları ve benzeri modeller, lineer olmayan ilişkileri yakalama konusunda sınırlı olup aşırı uyum riski taşımaktadır. Yoksulluk sınırını belirlemek için kullanılan yöntemler ise bölgesel maliyet farklılıkları, hane büyüklüğü ve diğer sosyo-ekonomik faktörleri dikkate almakta olup bu faktörlerin tam olarak nasıl ve ne ölçüde dikkate alındığı, tahminlerin doğruluğunu etkileyebilen faktörler olarak değerlendirilebilir.

Analize ilişkin kısıtlarda ise anket verilerinin, tabakalı iki aşamalı küme örnekleme yöntemi kullanılarak toplanmış olması, örnekleme hatasını azaltmak için tasarlanmış olsa da gelişigüzel hata oluşma olasılığını tamamen ortadan kaldırmamaktadır. Veri setindeki eksiklikler, yanlışlıklar veya veri kalitesi sorunları da analiz sonuçlarını etkileme potansiyeline sahiptir.

Yoksulluk anlayışı ve ölçüm kısıtlarında ise yoksulluğun sadece gelir ve tüketim harcamalarına değil, eğitim, sağlık, temiz su ve sanitasyon gibi temel hizmetlere erişim gibi çeşitli faktörlere de bağlı olması nedeniyle bu faktörlerin tamamının kapsamlı bir şekilde dikkate alınması, veri kısıtlamaları nedeniyle güçtür. Bu kısıtlar, tezin sonuçlarının ne kadar genellenebilir olduğunu ve yoksulluk tahminlerinin de ne kadar doğru olduğunu anlamak için önemlidir. Dolayısıyla yoksullukla mücadele etmek için

etkili politikalar geliřtirmek amacıyla, bu kısıtların dikkate alınması ve gelecekteki alıřmalara ışık tutması beklenmektedir.

## KAYNAKÇA

- AFZAL, M., Hersh, J., & Newhouse, D. (2015). Building a Better Model: Variable Selection to Predict Poverty in Pakistan and Sri Lanka.**
- ALKIRE, S., & Foster, J E. (2011, August 1). Counting and multidimensional poverty measurement.** Elsevier BV, 95(7-8), 476-487.  
<https://doi.org/10.1016/j.jpubeco.2010.11.006>
- ANAND, S., & SEN, A. (1994, January 1). Human Development Index: Methodology and Measurement. , 12.**  
<http://scholar.harvard.edu/sen/publications/human-development-index-methodology-and-measurement>
- ATKINSON, A B. (1987, July 1). On the Measurement of Poverty. Wiley-Blackwell, 55(4), 749-749.** <https://doi.org/10.2307/1911028>
- AULIA, T.F., Wijaya, D.R., Hernawati, E., & Hidayat, W.Y. (2020). Poverty Level Prediction Based on E-Commerce Data Using K-Nearest Neighbor and Information-Theoretical-Based Feature Selection.** 2020 3rd International Conference on Information and Communications Technology (ICOIACT), 28-33.
- AYUSH, K., UzKent, B., Tanmay, K., Burke, M., Lobell, D., & Ermon, S. (2021). Efficient Poverty Mapping from High Resolution Remote Sensing Images.** AAAI Conference on Artificial Intelligence,  
<https://doi.org/10.48550/arXiv.2006.04224>
- BABENKO, B., Hersh, J., Newhouse, D., Ramakrishnan, A., & Swartz, T. (2017). Poverty Mapping Using Convolutional Neural Networks Trained on High and Medium Resolution Satellite Images, With an Application in Mexico.** ArXiv, abs/1711.06323.
- BETTI, G., Dabalén, A.L., Ferré, C., & Neri, L. (2013). Updating Poverty Maps Between Censuses: A Case Study of Albania.**

**BIAU, G., & Scornet, E.** (2016, April 19). **A Random Forest Guided Tour.** Springer Science+Business Media, 25(2), 197-227. <https://doi.org/10.1007/s11749-016-0481-7>

**BIGSTEN, A., & SHIMELES, A.** (2008, September 5). **Poverty Transition and Persistence in Ethiopia: 1994-2004.** <https://www.sciencedirect.com/science/article/pii/S0305750X08000958>

**BUĞRA, A.** (2007, February 1). **Poverty and Citizenship: An Overview of The Social-Policy Environment in Republican Turkey.** Cambridge University Press, 39(1), 33-52. <https://doi.org/10.1017/s0020743807212528>

**BROWNE C, Matteson DS, McBride L, Hu L, Liu Y, Sun Y, et al.** (2021) **Multivariate Random Forest Prediction Of Poverty And Malnutrition Prevalence.** PLoS ONE 16(9): e0255519. <https://doi.org/10.1371/journal.pone.0255519>

**CANBAY, T., & Selim, S.** (2010). **Household Poverty in Turkey.** Ege Academic Review, 10(2), 627-649.

**CAPLAN, M., Washington, T., & Swanner, L.** (2017, June 22). **Beyond Income: A Social Justice Approach to Assessing Poverty among Older Adults with Chronic Kidney Disease.** Taylor & Francis, 60(6-7), 553-568. <https://doi.org/10.1080/01634372.2017.1344174>

**CHEN, T., & Guestrin, C.** (2016, August 13). **XGBoost.** <https://doi.org/10.1145/2939672.2939785>

**CHRIS, F.** (2016, March 18). **The Relationship Between Size of Living Space and Subjective Well-Being - Journal of Happiness Studies.** <https://link.springer.com/article/10.1007/s10902-016-9732-2>

**CONCIALDI, P.** (2018, March 1). **What does it mean to be rich? Some conceptual and empirical issues.** SAGE Publishing, 20(1), 3-20. <https://doi.org/10.1177/1388262718760911>

**D. R. Wijaya, N. L. Paramita, A. Uluwiyah, M. Rheza, A. Zahara, and D. R. Puspita** (2020), “**Estimating city-level poverty rate based on e-commerce data**

**with machine learning,”** Electronic Commerce Research, vol. 22, no. 1, pp. 195–221.

**DAOUD, E A.** (2019, January 15). **Comparison between XGBoost, LightGBM and CatBoost Using a Home Credit Dataset.** , 13(1), 6-10.  
<https://doi.org/10.5281/zenodo.3607805>

**DAS, P.S., Chhabra, H., & Dubey, S.K.** (2020). **Socio Economic Analysis of India with High Resolution Satellite Imagery to Predict Poverty.** 10th International Conference on Cloud Computing, Data Science & Engineering (Confluence), 310-314.

**DEĞİRMENCİ, N.** (2020). **Hanehalkı Sorumlusunun Yoksulluk Olasılığını Etkileyen Demografik Özellikleri: Düzey 1 Bölgeleri.** İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi, 19(39), 858-868.  
<https://doi.org/10.46928/iticusbe.753284>

**ENGSTROM, R., Pavelesku, D., Tanaka, T., & Wambile, A.** (2019). **Mapping Poverty and Slums Using Multiple Methodologies in Accra, Ghana. 2019 Joint Urban Remote Sensing Event (JURSE).**  
<https://doi.org/10.1109/jurse.2019.8809052>

**GALGO, J.** (2020, November 3). **Endeavours towards Academic Success: An Investigation of Underprivileged Student’s Life Experience.** , 1(2), 94-106.  
<https://doi.org/10.47631/mejress.v1i2.46>

**GEMİCİOĞLU, S.** (2022). **Hanehalkı Tipinin Yoksulluk ve Ekonomik Zorluk Çekme Riski Üzerindeki Etkisi.** Uluslararası Ekonomi ve Yenilik Dergisi, 8(2), 121–142.

**GUTIÉRREZ-ROMERO, R., & Ahamed, M M.** (2021, February 1). **COVID-19 response needs to broaden financial inclusion to curb the rise in poverty.** Elsevier BV, 138, 105229-105229. <https://doi.org/10.1016/j.worlddev.2020.105229>

**H. Zixi** (2021), "**Poverty Prediction Through Machine Learning,**" 2021 2nd International Conference on E-Commerce and Internet Technology (ECIT), Hangzhou, China, pp. 314-324, doi: 10.1109/ECIT52743.2021.00073.

**HANG, H.,** Huang, T., Cai, Y., Yang, H., & Lin, Z. (2021, January 1). **Gradient Boosted Binary Histogram Ensemble for Large-scale Regression.** Cornell University. <https://doi.org/10.48550/arxiv.2106.01986>

**HERNANDEZ, M.A.,** Hong, L., Frías-Martínez, V., Whitby, A., & Frías-Martínez, E. (2017). **Estimating Poverty Using Cell Phone Data: Evidence from Guatemala.** *Development Economics: Microeconomic Issues in Developing Economies eJournal.*

History of Poverty Thresholds. <https://aspe.hhs.gov/topics/poverty-economic-mobility/poverty-guidelines/further-resources-poverty-measurement-poverty-lines-their-history/history-poverty-thresholds>

**HU, S.,** Ge, Y., Liu, M., Ren, Z., & Zhang, X. (2022). **Village-Level Poverty Identification Using Machine Learning, High-Resolution Images, And Geospatial Data.** *International Journal of Applied Earth Observation and Geoinformation*, 107, 102694. <https://doi.org/10.1016/j.jag.2022.102694>

**JAMALUDDIN, Z.,** & Hanafiah, N M A. (2020, August 16). **Poverty and Productive Welfare in Malaysia**, 10(8). <https://doi.org/10.6007/ijarbss/v10-i8/7661>

**JEAN, N.,** Burke, M., Xie, M., Davis, W. M., Lobell, D. B., & Ermon, S. (2016). **Combining Satellite Imagery And Machine Learning To Predict Poverty.** *Science (New York, N.Y.)*, 353(6301), 790–794. <https://doi.org/10.1126/science.aaf7894>

**KAKWANI, N.** (1993, November 1). **Statistical Inference in the Measurement of Poverty.** *The MIT Press*, 75(4), 632–632. <https://doi.org/10.2307/2110016>

**KÄLLESTÅL, C.,** Blandón Zelaya, E., Peña, R., Pérez, W., Contreras, M., Persson, L.Å., Sysoev, O., & Ekholm Selling, K. (2019). **Predicting poverty. Data mining approaches to the health and demographic surveillance system in Cuatro Santos, Nicaragua.** *International Journal for Equity in Health*, 18.

**KODURU, M.** (2020, July 16). **RF-XGBoost Model for Loan Application Scoring in Non Banking Financial Institutions.** *International Research Publication House*, V9(07). <https://doi.org/10.17577/ijertv9is070117>

- KSHIRSAGAR, V.**, Wieczorek, J., Ramanathan, S., & Wells, R.D. (2017). Household Poverty Classification In Data-Scarce Environments: A Machine Learning Approach. arXiv: Machine Learning, <https://doi.org/10.48550/arXiv.1711.06813>
- LÍ, Q.**; Yu, S.; Échevin, D.; Fan, M. (2021) **Is poverty predictable with machine learning? A study of DHS data from Kyrgyzstan.** Socio-Econ. Plan. Sci., 81, 101195.
- LUSARDI, A.**, Cossa, R., & Krupka, E L. (2001, January 1). **Savings of Young Parents.** University of Wisconsin Press, 36(4), 762-762. <https://doi.org/10.2307/3069641>
- MANDRELL, C.**, Holland, T., Wheeler, J F., Esmacili, S M A., Amar, K., Chowdhury, F., & Sivakumar, P. (2020, September 5). **Machine Learning Approach to Raman Spectrum Analysis of MIA PaCa-2 Pancreatic Cancer Tumor Repopulating Cells for Classification and Feature Analysis.** Multidisciplinary Digital Publishing Institute, 10(9), 181-181. <https://doi.org/10.3390/life10090181>
- MANSHOR, Z.**, Abdullah, S., & Hamed, A B. (2020, March 24). **Poverty and the Social Problems.** [https://hrmars.com/papers\\_submitted/7076/Poverty\\_and\\_the\\_Social\\_Problems.pdf](https://hrmars.com/papers_submitted/7076/Poverty_and_the_Social_Problems.pdf)
- MAYAN, S N A.**, & Nor, R M. (2020, September 27). **The Resistance of the Urban Poor in Selangor, Malaysia to Get Out of the Shackles of Poverty.** , 10(9). <https://doi.org/10.6007/ijarbss/v10-i9/7837>
- MCNUTT, S.**, Zimmerman, T P., & Hull, S G. (2008, February 1). **Development of food composition databases for food frequency questionnaires (FFQ).** Elsevier BV, 21, S20-S26. <https://doi.org/10.1016/j.jfca.2007.05.007>
- MUDEREDZI, J.**, Eide, A H., Braathen, S H., & Stray-Pedersen, B. (2019, June 11). **Exploring the Relationship Between Food Insecurity, Gender Roles and HIV/AIDS Among Tonga Carers of Disabled Children of Binga in Zimbabwe.** Springer Science+Business Media, 23(4), 1131-1146. <https://doi.org/10.1007/s12119-019-09610-w>

**MWABU, G., Kimenyi, M.S., Kimalu, P.K., Nafula, N.N., & Manda, D.K. (2003). Predicting Household Poverty: A Methodological Note with a Kenyan Example. African Development Review, 15, 77-85.**

**NAIR, V S., Kidambi, R., Sellamanickam, S., Keerthi, S S., Gehrke, J., & Narayanan, V K. (2013, November 10). A Quantitative Evaluation Framework for Missing Value Imputation Algorithms. Cornell University.**  
<https://arxiv.org/pdf/1311.2276>

**OLIVIA, S., Gibson, J., Rozelle, S., Huang, J., & Deng, X. (2011). Mapping Poverty In Rural China: How Much Does The Environment Matter? Environment And Development Economics, 16(2), 129-153.**  
 Doi:10.1017/S1355770x10000513

**ÖNDER, H., Şenses, F. (2006), “Türkiye’de Yoksulluk ve Yoksulluk Düşüncesi”, İktisat, Siyaset, Devlet Üzerine Yazılar, ss. 199-221.**

**PAVE SOHNESEN, Thomas & Stender, Niels, (2016). "Is random forest a superior methodology for predicting poverty? an empirical assessment," Policy Research Working Paper Series 7612, The World Bank.**

**PIAGGESÌ, S., Gauvin, L., Tizzoni, M., Cattuto, C., Adler, N., Verhulst, S.G., Young, A., Price, R., Ferres, L., & Panisson, A. (2019). Predicting City Poverty Using Satellite Imagery. CVPR Workshops.**

**POKHRIYAL, N. (2019). Multi-View Learning from Disparate Sources for Poverty Mapping. AAAI Conference on Artificial Intelligence.**

**POKHRIYAL, N., & Jacques, D. C. (2017). Combining Disparate Data Sources For Improved Poverty Prediction And Mapping. Proceedings of the National Academy of Sciences, 114(46). <https://doi.org/10.1073/pnas.1700319114>**

**PRAJAPATI, G L., & Patle, A. (2010, November 1). On Performing Classification Using SVM with Radial Basis and Polynomial Kernel Functions. <https://doi.org/10.1109/icetec.2010.134>**

**RAVALLION, M. (1998, July 20). Poverty Lines in Theory and Practice. <https://doi.org/10.1596/0-8213-4226-6>**

**ROBINSON, T., Emwanu, T., & Rogers, D. (2007). Environmental Approaches to Poverty Mapping: an example from Uganda.** *Information Development*, 23(2–3), 205–215. <https://doi.org/10.1177/0266666907079077>

**SEN, A. (1999). Development as Freedom.** Knopf.

**SHENG, W., & Yumei, S. (2021). Prediction Poverty Levels Of College Students Using A Machine Learning Model.** <https://doi.org/10.21203/rs.3.rs-919541/v1>

**SOLIS-SALAZAR, M., & Madrigal-Sanabria, J. (2022). Una Propuesta De Aprendizaje Automático Para Predecir La Pobreza (A Machine Learning Proposal To Predict Poverty).** *Revista Tecnología En Marcha*. <https://doi.org/10.18845/tm.v35i4.5766>

**SUBASH, S.P, Kumar, R.R, Aditya, K.S. (2019). Satellite Data And Machine Learning Tools For Predicting Poverty In Rural India.** *Agricultural Economics Research Review*. 31. 231-240. 10.5958/0974-0279.2018.00040.

**SUGASAWA, S., Kubokawa, T., & Rao, J N K. (2018, December 21). Hierarchical Bayes Small-Area Estimation with An Unknown Link Function.** *Wiley*, 46(3), 885-897. <https://doi.org/10.1111/sjos.12376>

**SYMACO, L P. (2013, July 2). Geographies of social exclusion: education access in the Philippines.** *Taylor & Francis*, 49(3), 361-373. <https://doi.org/10.1080/03050068.2013.803784>

**ŞENTÜRK O., Çelik N. Türkiye'de Hanehalkı Yoksulluğunu Etkileyen Faktörlerin Belirlenmesi.** *İstatistik Araştırma Dergisi*, 2021, 11 (2), 56-70.

**TAROZZI, A., & Deaton, A. (2007). Using Census and Survey Data to Estimate Poverty and Inequality for Small Areas.** *The Review of Economics and Statistics*, 91, 773-792.

**TAUD, H., & Mas, J. (2017, October 28). Multilayer Perceptron (MLP).** *Springer Nature*, 451-455. [https://doi.org/10.1007/978-3-319-60801-3\\_27](https://doi.org/10.1007/978-3-319-60801-3_27)

**TILAK, J B G. (2010, August 3). Education and Poverty.**

**TINGZON, I., Orden, A., Go, K. T., Sy, S., Sekara, V., Weber, I., Fatehkia, M., García-Herranz, M., & Kim, D. (2019, December 23). Mapping Poverty In The Philippines Using Machine Learning, Satellite Imagery, And Crowd-Sourced Geospatial Information.** The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-4/W19, 425–431.  
<https://doi.org/10.5194/isprs-archives-xlii-4-w19-425-2019>

**TURNA, Y. (2022). Türkiye’de Göreli Yoksulluğa Neden Olan Faktörler: Yapay ve Zeka Tahmin Yöntemleri Uygulamaları (Pamukkale Üniversitesi). Sosyal Bilimler Enstitüsü, Yayınlanmamış Doktora Tezi, Denizli.**

**TÜİK (2019). Türkiye İstatistik Kurumu, Hanehalkı Bütçe Anketi 2019,** Ankara.

**TÜİK (2022). “Resmi İstatistik Programı 2022-2026”,** Ankara.

**TÜİK, Hanehalkı Bütçe Araştırması Tüketim Harcamaları Birleşik Mikro Veri Seti, Ocak-2020.** <https://www.tuik.gov.tr/media/microdata/pdf/hanehalki-butce.pdf> adresinden alındı. Erişim Tarihi: 08 Ocak 2023

**TOPAL, K. H., & Çağlayan Akay, E. (2021). Hanehalkı Tüketim Harcamalarının Mikroekonometrik Analizi: LAD-LASSO Yöntemi.** EKOİST Journal of Econometrics and Statistics(33), 13-31.  
<https://doi.org/10.26650/ekoist.2020.33.843564>

**UN (2022), The Sustainable Development Goals Report 2022.** New York, USA: UN DESA. <https://unstats.un.org/sdgs/report/2022/>

**VIDYASAGAR, D. (2006, May 4). Global Notes: Counting The World's Poor – How Do We Define Poverty?.** Springer Nature, 26(6), 325-327.  
<https://doi.org/10.1038/sj.jp.7211531>

**VYAS S, Kumaranayake L. Constructing socio-economic status indices: how to use principal components analysis. Health Policy Plan.** 2006 Nov;21(6):459-68. doi: 10.1093/heapol/czl029. Epub 2006 Oct 9. PMID: 17030551.

**WATMOUGH, G. R., Marcinko, C. L. J., Sullivan, C., TSCHIRHART, K., MUTUO, P. K., Palm, C. A., & Svenning, J. C. (2019, January 7). Socioecologically Informed Use Of Remote Sensing Data To Predict Rural**

**Household Poverty.** Proceedings of the National Academy of Sciences, 116(4), 1213–1218. <https://doi.org/10.1073/pnas.1812969116>

**WOLFF, E N.** (2003, September 5). **Household Wealth, Public Consumption, and Economic Well-Being in the United States.** <https://papers.ssrn.com/sol3/papers.cfm>

World Bank (2005), “**Turkey Joint Poverty Assessment Report** (Report No: 29619-TU),” Human.

World Bank (2015)  
<https://www.worldbank.org/en/news/speech/2015/04/07/speech-by-world-bank-group-president-jim-yong-kim-ending-extreme-poverty-final-push> adresinden alındı. Erişim tarihi: 10 Ocak 2023

**XIAO, Y.** (2021). **Predicting Poverty through Machine Learning and Satellite Images.** 2021 International Conference on Digital Society and Intelligent Systems (DSInS), 182-187.

**XIE, M., Jean, N., Burke, M., Lobell, D., & Ermon, S.** (2016). **Transfer Learning From Deep Features For Remote Sensing And Poverty Mapping.** Proceedings of the AAAI Conference on Artificial Intelligence, 30(1).  
<https://doi.org/10.1609/aaai.v30i1.9906>

**YANG, J., Ip, W F., Vong, C., & Wong, P K.** (2011, June 1). **Effect Of Choice of Kernel in Support Vector Machines on Ambient Air Pollution Forecasting.** <https://doi.org/10.1109/icsse.2011.5961964>

**YANTO, M., Wiyandra, Y., & Defit, S.** (2023). **Deep Learning Approach Analysis Model Prediction And Classification Poverty Status.** IAES International Journal of Artificial Intelligence (IJ-AI), 12(1), 459.  
<https://doi.org/10.11591/ijai.v12.i1.pp459-468>

**ZULKIFLI, F., & Abidin, R Z.** (2023, June 17). **The Multi-Dimensional Nature of Poverty: A Review of Contemporary Research.** , 12(2).  
<https://doi.org/10.6007/ijarems/v12-i2/17260>

