



T.C.

ALANYA ALAADDİN KEYKUBAT ÜNİVERSİTESİ

LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

ULUSLARARASI TİCARET ANA BİLİM DALI

**OECD ÜLKELERİNİN LOJİSTİK GÖSTERGELERİ İLE VERİ
MADENCİLİĞİ UYGULAMALARI**

Doktora Tezi

Burcu YAMAN SELÇİ

Danışman

Prof. Dr. Yakup AKGÜL

ALANYA

2025

T.C.
ALANYA ALAADDİN KEYKUBAT ÜNİVERSİTESİ
LİSANSÜSTÜ EĞİTİM ENSTİTÜSÜ

OECD ÜLKELERİNİN LOJİSTİK GÖSTERGELERİ İLE VERİ
MADENCİLİĞİ UYGULAMALARI

Doktora Tezi

Burcu Yaman Selçi

Anabilim Dalı: Uluslararası Ticaret

Program Adı: Uluslararası Ticaret

Danışman
Prof. Dr. Yakup AKGÜL

ALANYA
(2025)

ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ

Bu tezin bana ait, özgün bir çalışma olduğunu; çalışmamın hazırlık, veri toplama, analiz ve bilgilerin sunumu olmak üzere tüm aşamalarında bilimsel etik ilke ve kurallara uygun davrandığımı; bu çalışma kapsamında elde edilemeyen tüm veri ve bilgiler için kaynak gösterdiğimi ve bu kaynaklara kaynakçada yer verdiğimi; bu çalışmanın Alanya Alaaddin Keykubat Üniversitesi tarafından kullanılan “bilimsel intihal tespit programıyla tarandığını ve “intihal içermediğini” beyan ederim. Herhangi bir zamanda, çalışmamla ilgili yaptığım bu beyana aykırı bir durumun saptanması durumunda, ortaya çıkacak tüm ahlaki ve hukuki sonuçlara razı olduğumu bildiririm.

Burcu YAMAN SELÇİ

TEŞEKKÜR

Öncelikle yüksek lisans ve doktora eğitimim boyunca sahip olduğu bilgi birikimi ile bana rehberlik ederek akademik gelişimime yadsınamaz katkılarda bulunan değerli danışmanım Prof. Dr. Yakup AKGÜL'e teşekkürü bir borç bilirim. Tez İzleme Komitesi'nde yer alan ve yapıcı yaklaşımları ile tezimin şekillenmesinde büyük katkıları olan Doç. Dr. Ali Osman UYMAZ ve Dr. Öğretim Üyesi Tahire HÜSEYİNLİ'ye teşekkürlerimi sunarım. Savunma jürisinde yer alan ve tezin derinleştirilmesine katkıda bulunan Doç. Dr. Nuri AVŞARLIGİL ve Dr. Öğretim Üyesi Zeynep GÜNAY'a da şükranlarımı sunarım. Son olarak doktora sürecim boyunca benden akademik bilgi ve manevi desteğini hiçbir zaman esirgemeyen Doç. Dr. Yakup ARI'ya ayrıca teşekkür ederim.

Sevgisi ve desteği ile bana tüm zorlukları aşacak kuvveti veren *ANNEME*, desteğini hiçbir zaman esirgemeyen *ABLAMA* ve bu yolda bana olan inancını her zaman fazlası ile hissettiren *EŞİME* çok teşekkür ederim. En büyük teşekkürü ise doktora sürecimde zorlandığım anlarda tüm stresimi alan *KIZIMA* sunarım.

Burcu YAMAN SELÇİ

ÖZET

OECD ÜLKELERİNİN LOJİSTİK GÖSTERGELERİ İLE VERİ MADENCİLİĞİ UYGULAMALARI

Burcu YAMAN SELÇİ

Uluslararası Ticaret Anabilim Dalı

Alanya Alaaddin Keykubat Üniversitesi, Lisansüstü Eğitim Enstitüsü,

Aralık, 2025 (145 Sayfa)

Günümüzde yaşanan teknolojik gelişmeler özellikle ekonomi ve lojistik alanlarında her geçen gün milyarlarca büyük verinin birikmesine sebebiyet vermektedir. Biriken büyük verinin veri madenciliğine özel yazılımlar kullanılarak analiz edilmesi ve böylelikle araştırmacılar ile politika yapıcılar için önemli bilgilerin açığa çıkarılması ise oldukça önemlidir. Bu çalışmanın amacı; OECD ülkelerine ait ekonomi ve lojistik alanlarında biriken büyük verinin analiz edilmesi ve politika çıkarımlarının gerçekleştirilmesidir. Çalışmanın amacı doğrultusunda WEKA 3.8.6 yazılımında ve STATA 16 paket programında uygulanan analizler dört adımda gerçekleştirilmiştir. İlk olarak, 29 OECD üyesi ülkeye ait GSYH, ihracat, ithalat, enflasyon ve işsizlik oranı değişkenleri ile 2013-2022 dönemleri için k-ortalamlar algoritması kullanılarak ayrı ayrı kümeleme analizi gerçekleştirilmiştir. Analiz sonucunda ülkeler dört kümeye ayrılmıştır. En gelişmiş ülkelerin yer aldığı kümede Almanya ve ABD'nin yer aldığı, Belçika, Fransa, Japonya, Kanada, Kore ve Birleşik Krallık'ın ise gelişmiş ülkeler oldukları belirlenmiştir. Yunanistan ve İspanya'nın gelişmekte olan ülkeleri temsil ettiği; Türkiye'nin ise özellikle son yıllarda gelişmekte olan ülkelere biri konumuna geldiği görülmüştür. Estonya, Letonya ve Litvanya ise az gelişmiş ülkeleri temsil eden kümede yer almışlardır. Analizin ikinci aşamasında, OECD ülkelerine ait 20 adet taşımacılık değişkeninin 2019 yılına ait verileri ile sınıflandırıcı yöntemlerden birisi olan karar ağaçlarının J48 algoritması kullanılarak ülkeler arasında farklılaşmaya neden olan lojistik göstergeler belirlenmiştir. Ülkelerin ekonomik gelişme düzeylerinin farklılaşmasına neden olan taşımacılık değişkenlerinin demiryolu altyapı yatırımı, GSYH başına düşen toplam iç ulaşım altyapı yatırımı, kişi başına düşen demiryolu altyapı yatırımı ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payı olduğu saptanmıştır. Üçüncü olarak, OECD ülkelerinin ekonomik gelişme

düzeylerini farklılaştırdığı tespit edilen bu dört adet taşımacılık değişkeninin 2025 yılına yönelik öngörülerini yapay sinir ağları kullanılarak her bir ülke için ayrı ayrı gerçekleştirilmiştir. Analizin son adımında ise, demiryolu altyapı yatırımlarının, kişi başına düşen demiryolu altyapı yatırımlarının, GSYH başına düşen toplam iç ulaşım altyapı yatırımlarının ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının ekonomik büyümeye etkisi Driscoll-Kraay tahmincisi kullanılarak incelenmiştir. Analiz, OECD ülkelerinin 2010-2019 dönemini kapsayan yıllık verileri kullanılarak gerçekleştirilmiştir. Analizin sonucunda, demiryolu altyapı yatırımı ve kişi başına düşen demiryolu altyapı yatırımının GSYH üzerindeki etkisinin istatistiki olarak anlamsız olduğu tespit edilir iken; GSYH başına düşen toplam iç ulaşım altyapı yatırımı ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının GSYH üzerindeki etkisinin istatistiki olarak anlamlı olduğu saptanmıştır.

Anahtar Sözcükler: Veri Madenciliği, Kümeleme Analizi, Karar Ağacı, Yapay Sinir Ağları, Panel Regresyon Analizi.

ABSTRACT

DATA MINING APPLICATIONS WITH LOGISTICS INDICATORS OF OECD COUNTRIES

Burcu YAMAN SELÇİ

Department of International Trade

Graduate School of Alanya Alaaddin Keykubat University,

December. 2025

Today's technological developments cause the accumulation of billions of big data, especially in the fields of economy and logistics. It is very important to analyse the accumulated big data using special software for data mining so that it reveals important information for researchers and policymakers. The aim of this study is to analyse the big data accumulated in the economic and logistics fields of OECD countries and to make comprehensive policy inferences. In line with the purpose of the study, the analyses applied in WEKA 3.8.6 software and STATA 16 package program were carried out in four steps. First of all, cluster analysis was carried out separately using the k-means algorithm for the GDP, export, import, inflation, and unemployment rate variables of 29 OECD member countries for the period 2013-2022. As a result of the analysis, countries were divided into four clusters. Germany and the USA were included in the cluster of the most developed countries, while Belgium, France, Japan, Canada, Korea and the United Kingdom were determined to be developed countries. Greece and Spain represent developing countries, while Turkey has become a developing country, particularly in recent years. Estonia, Latvia, and Lithuania are included in the cluster representing less developed countries. In the second stage of the analysis, logistic indicators that cause differences between countries were determined using the 2019 data of 20 transportation variables of OECD countries and the J48 algorithm of decision trees, one of the classifier methods. It has been determined that the transportation variables that cause the differences in the economic development levels of countries are railway infrastructure investment, total domestic transport infrastructure investment per GDP, railway infrastructure investment per capita and the share of CO₂ emissions from international aviation bunkers in total CO₂ emissions. Thirdly, the 2025 forecasts of these four

transportation variables, which were found to differentiate the economic development levels of OECD countries, were made separately for each country using artificial neural networks. In the last step of the analysis, the effects of railway infrastructure investments, railway infrastructure investments per capita, total domestic transport infrastructure investments per GDP, and the share of CO₂ emissions from international aviation bunkers in total CO₂ emissions on economic growth were examined using the Driscoll-Kraay estimator. The analysis was carried out by using annual data of OECD countries covering the period 2010-2019. According to result of the analysis, it was determined that the effect of railway infrastructure investment and per capita railway infrastructure investment on GDP was statistically insignificant, while the effect of total domestic transport infrastructure investment per GDP and the share of CO₂ emissions from international aviation bunkers in total CO₂ emissions on GDP was statistically significant.

Keywords: Data Mining, Cluster Analysis, Decision Tree, Artificial Neural Networks, Panel Regression Analysis.

İÇİNDEKİLER

JÜRİ VE ENSTİTÜ ONAYI	i
ETİK İLKE VE KURALLARA UYGUNLUK BEYANNAMESİ	ii
TEŞEKKÜR.....	iii
ÖZET	iv
ABSTRACT.....	vi
TABLolar LİSTESİ.....	xi
ŞEKİLLER LİSTESİ	xii
SİMGELER VE KISALTMALAR	xiv
GİRİŞ	1
1. BÖLÜM.....	5
KÜMELEME ANALİZİ.....	5
GİRİŞ	7
1.1. Literatür taraması	8
1.2. Araştırma Metodolojisi ve Veri Seti	11
1.2.1. Büyük verinin kavramsal olarak ortaya çıkışı ve özellikleri	11
1.2.2. Büyük verinin analizinde veri madenciliğinin kullanımı	13
1.2.3. Veri madenciliği	13
1.2.4. Kümeleme analizi	14
1.2.5. Veri seti ve veri dönüşümü.....	16
1.3. Uygulama ve Bulgular	18
1.3.1 Kümeleme analizinin uygulanması ve bulgular	18
1.4. Tartışma.....	27
1.5. Çıkarımlar	30
1.5.1. Teorik ve uygulama çıkarımları	30
1.6. Sonuç ve Öneriler.....	31
1.7. Çalışmanın Kısıtlılıkları ve Gelecekle İlgili Yönelimler	34
2. BÖLÜM.....	36
KARAR AĞAÇLARI.....	36
GİRİŞ	38
2.1. Literatür Taraması.....	39
2.2. Araştırma Metodolojisi ve Veri Seti	41
2.2.1. Veri madenciliği süreci ve yöntemleri	41

2.2.1.1. Tahmin edici yöntemler	42
2.2.1.1.1. Karar ağaçları	44
2.2.1.2 Tanımlayıcı yöntemler	45
2.2.2. Veri seti ve veri dönüşümü	46
2.3. Uygulama ve Bulgular	48
2.4. Tartışma.....	53
2.5. Çıkarımlar	56
2.5.1. Teorik ve uygulama çıkarımları	56
2.6. Sonuç ve Öneriler.....	57
2.7. Çalışmanın Kısıtlılıkları ve Gelecekle İlgili Yönelimler	60
3. BÖLÜM.....	61
YAPAY SİNİR AĞLARI İLE ÖNGÖRÜ	61
GİRİŞ	64
3.1. Literatür Taraması	66
3.2. Araştırma Metodolojisi ve Veri Seti	68
3.2.1. Yapay sinir ağlarının tanımı ve özellikleri	68
3.2.2. Veri seti ve veri dönüşümü.....	72
3.3. Uygulama ve Bulgular.....	74
3.4. Tartışma.....	93
3.5. Çıkarımlar	97
3.5.1. Teorik ve uygulama çıkarımları	97
3.6. Sonuç ve Öneriler.....	98
3.7. Çalışmanın Kısıtlılıkları ve Gelecekle İlgili Yönelimler	100
4. BÖLÜM.....	102
PANEL REGRESYON ANALİZİ	102
GİRİŞ	105
4.1. Literatür Taraması	107
4.2. Lojistik Kavramı ve Gelişimi.....	110
4.3. Ulaştırma-Taşıma, Lojistik ve Ekonomi İlişkisi	113
4.3.1. Ulaştırma-taşıma ve lojistik ilişkisi	113
4.3.2. Ekonomi ve lojistik ilişkisi.....	114
4.4. Araştırma Modeli ve Veri Seti	117
4.5. Metodoloji ve Bulgular	118
4.5.1. Panel veri modelinin belirlenmesi	119

4.5.2. Panel regresyon analizi	122
4.6. Tartışma.....	123
4.7. Çıkarımlar	126
4.7.1. Teorik ve uygulama çıkarımları	126
4.8. Sonuç ve Öneriler.....	127
4.9. Çalışmanın Kısıtlılıkları ve Gelecekle İlgili Yönelimler	129
5. SONUÇ.....	131
6. KAYNAKÇA	135
ÖZGEÇMİŞ	144



TABLÖLER LİSTESİ

Tablo 1.1. Kümeleme Analizi Yapılan Çalışmalar	9
Tablo 1.2. Kümeleme Analizi İçin Seçilen Değişkenlere Ait Bilgiler.....	17
Tablo 1.3. Kümeleme Analizi İçin Seçilen OECD Üyesi Ülkeler.....	17
Tablo 1.4. Kümeleme Analizi Sonuçları	21
Tablo 1.5. GSYH, İhracat ve İthalat Değişkenlerinin Son Küme Merkezleri.....	26
Tablo 1.6. Enflasyon ve İşsizlik Oranı Değişkenlerinin Son Küme Merkezleri	26
Tablo 2.1. Karar ağaçları Algoritmaları Kullanılarak Yapılan Çalışmalar	40
Tablo 2.2. Kümeleme ve Karar Ağacı Analizleri İçin Seçilen OECD Üyesi Ülkeler	47
Tablo 2.3. Kümeleme Analizinde Kullanılan Makroekonomik Değişkenler	47
Tablo 2.4. Karar Ağaçları ile Yapılan Analizde Kullanılan Taşımacılık Değişkenleri ...	47
Tablo 2.5. 2019 Yılına Ait Kümeleme Analizi Sonuçları.....	49
Tablo 2.6. 2019 Yılına Ait Son Küme Merkezleri.....	50
Tablo 2.7. Eğitim ve Test Veri Kümelerinin Sınıflandırma Başarıları	52
Tablo 3.1. Yapay Sinir Ağları Kullanarak Yapılan Çalışmalar	66
Tablo 3.2. Öngörü Modeli İçin Seçilen OECD Üyesi Ülkeler ve Seçilen Yıl Aralıkları	72
Tablo 3.3. Öngörü Modeli İçin Seçilen Değişkenler.....	73
Tablo 3.4. Öngörü Modeline Ait Eğitim ve Test Veri Kümeleri	75
Tablo 3.5. Çok Katmanlı Ağlarla Kurulan Modellerde Test Veri Kümelerine İlişkin MAPE Değerleri	77
Tablo 3.6. Çok Katmanlı Ağlar ile Yapılan Öngörülerin Gerçek Değerler ile Karşılaştırılması.....	76
Tablo 4.1. Ulaşım Altyapısının Ekonomik Büyüme Üzerindeki Etkisini İnceleyen Çalışmalar	107
Tablo 4.2. Panel Regresyon Analizi İçin Seçilen OECD Üyesi Ülkeler	117
Tablo 4.3. Panel Regresyon Analizinde Kullanılan Değişkenler	118
Tablo 4.4. Çoklu Doğrusal Bağlantının Varyans Büyütme Faktörü (VIF) İle Sınanması	119
Tablo 4.5. Panel Etkilerin Varlığının Sınanması	120
Tablo 4.6. Hausman Testi Sonuçları.....	121
Tablo 4.7. Sabit Etkiler Modelinde Değişen Varyans, Otokorelasyon ve Birimler Arası Korelasyonun Sınanması	122
Tablo 4.8. Sabit Etkili Driscoll-Kraay Tahmincisi Sonuçları.....	123

ŞEKİLLER LİSTESİ

Şekil 1.1. Kümeleme Teknikleri	16
Şekil 1.2. WEKA Ara Yüzünün Görünümü.....	20
Şekil 1.3. K-ortalamalar Kümeleme Algoritması İçin Yüzdelik Küme Dağılımları	220
Şekil 2.1. Veri Madenciliği Yöntemleri	42
Şekil 2.2. Basit bir Karar Ağacının Yapısı	45
Şekil 2.3. WEKA Arayüz Ekranı	51
Şekil 2.4. J48 Algoritmasının Uygulanması Sonucunda WEKA Arayüz Ekranı	52
Şekil 2.5. Karar Ağaçlarına Ait Dendogram.....	53
Şekil 3.1. Gerçek Bir Sinir Hücresinin Bileşenleri.....	69
Şekil 3.2. Yapay Bir Sinir Hücresinin Bileşenleri	70
Şekil 3.3. Yapay Sinir Ağının Genel Yapısı.....	70
Şekil 3.4. Çok Katmanlı Algılayıcı.....	72
Şekil 3.5. ÇKA ile Avustralya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	82
Şekil 3.6. ÇKA ile Avusturya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	82
Şekil 3.7. ÇKA ile Belçika'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	83
Şekil 3.8. ÇKA ile Kanada'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2019-2025 Yılları Arasındaki Öngörü Değerleri	83
Şekil 3.9. ÇKA ile Çek Cumhuriyeti'ne Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	84
Şekil 3.10. ÇKA ile Estonya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	84
Şekil 3.11. ÇKA ile Finlandiya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	85
Şekil 3.12. Doğrusal Regresyon ile Finlandiya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	85
Şekil 3.13. ÇKA ile Fransa'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	86
Şekil 3.14. Doğrusal Regresyon ile Fransa'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	87

Şekil 3.15. Doğrusal Regresyon ile Almanya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	87
Şekil 3.16. Doğrusal Regresyon ile Macaristan'a Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	88
Şekil 3.17. ÇKA ile İrlanda'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2019-2025 Yılları Arasındaki Öngörü Değerleri	88
Şekil 3.18. Doğrusal Regresyon ile İrlanda'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2019-2025 Yılları Arasındaki Öngörü Değerleri	89
Şekil 3.19. ÇKA ile İtalya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2020-2025 Yılları Arasındaki Öngörü Değerleri	89
Şekil 3.20. ÇKA ile Japonya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2019-2025 Yılları Arasındaki Öngörü Değerleri	90
Şekil 3.21. ÇKA ile Kore'ye Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2019-2025 Yılları Arasındaki Öngörü Değerleri	90
Şekil 3.22. Doğrusal Regresyon ile Kore'ye Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2019-2025 Yılları Arasındaki Öngörü Değerleri	91
Şekil 3.23. ÇKA ile Letonya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	92
Şekil 3.24. ÇKA ile Litvanya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	92
Şekil 3.25. Doğrusal Regresyon ile Litvanya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri	93
Şekil 3.26. ÇKA ile Lüksemburg'a Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2020-2025 Yılları Arasındaki Öngörü Değerleri	93
Şekil 4.1. Lojistik Kavramının Gelişimi.....	112
Şekil 4.2. Lojistiğin Ekonomik Büyüme Üzerindeki Etkisi	117

SİMGELER VE KISALTMALAR

AB: Avrupa Birliği

ABD: Amerika Birleşik Devletleri

ARFF: Öznitelik-İlişki Dosya Biçimi (Attribute-Relation File Format)

AYM: Avrupa Yeşil Mutabakatı

BRICS: Brezilya, Rusya, Hindistan, Çin ve Güney Afrika Cumhuriyeti Ekonomileri

CART: Sınıflandırma ve Regresyon Ağaçları (Classification and Regression Tree)

CHAİD: Ki-kare Otomatik Etkileşim Dedektörü (Chi-squared Automatic Interaction Detector)

CORSIA: Uluslararası Havacılığa Yönelik Karbon Denkleştirme ve Azaltma Şeması (Carbon Offsetting and Reduction Scheme for International Aviation)

Covid-19: Koronavirüs Hastalığı

CO₂: Karbondioksit

ÇKA: Çok Katmanlı Ağlar

ETS: Emisyon Ticaret Sistemi

€: Avro

G-20: 20 Grubu (Group of 20)

GDP: Gayrisafi Yurtiçi Hasıla (Gross Domestic Product)

GSYH: Gayrisafi Yurtiçi Hasıla (Gross Domestic Product)

IEA: Uluslararası Enerji Ajansı (International Energy Agency)

KM: Kilometre

MAE: Ortalama Mutlak Hata (Mean Absolute Error)

MAPE: Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error)

MENA: Middle East and North Africa

MSE: Hata Kareleri ortalaması (Mean Squared Error)

RMSE: Ortalama Hata Karelerinin Kökü (Root Mean Squared Error)

OECD: Ekonomik Kalkınma ve İş birliği Örgütü

SPSS: Statistical Package for the Social Sciences

\$: Dolar

TGV: Train à Grande Vitesse

VAR: Vektör Otoregresyon

VECM: Vektör Hata Düzeltme Modeli (Vector Error Correction)

VIF: Varyans Büyütme Faktörü (Variance Inflation Factor)

WEKA: Waikato Environment for Knowledge Analysis

YSA: Yapay Sinir Ağları



GİRİŞ

Günümüzde yaşanan teknolojik gelişmeler veri tabanlarında gün geçtikçe artan miktarda büyük verinin birikmesine sebebiyet vermektedir. Biriken büyük veri yığınları arasında ise çeşitli kurum ve kuruluşların yanı sıra çeşitli örgütler ve ülkeler için stratejik öneme sahip bilgiler de yer almaktadır. Ancak stratejik öneme sahip bu bilgilerin büyük veri yığınları arasından ayrıştırılarak açığa çıkarılması gerekmektedir. Tam da bu noktada veri madenciliği uygulamaları ön plana çıkmaktadır. Çünkü veri madenciliği uygulamalarında kullanılan istatistiki teknikler ve özel algoritmalar yardımı ile büyük veri yığınları içerisinde gerçekten stratejik öneme sahip bilgiler keşfedilebilmektedir.

Teknolojik gelişmelerin hızla büyük veri birikmesine sebep olduğu alanların başında ekonomi ve lojistik gelmektedir. Ekonomi ve lojistik alanlarında biriken büyük veri yığınları içerisinde özellikle araştırmacılar ve politika yapıcılar için stratejik öneme sahip bilgilerin açığa çıkarılması ve bu bilgiler ışığında doğru politikalar uygulanması gerekmektedir. Özellikle içerisinde hem gelişmekte olan hem de gelişmiş ülkelerin yer aldığı OECD (Organisation for Economic Co-Operation and Development) (Ekonomik Kalkınma ve İşbirliği Örgütü) üyesi ülkelerin ekonomi ve lojistik alanlarında biriken büyük verinin analiz edilerek politika çıkarımlarının yapılması sürdürülebilir büyümenin ve dolayısı ile de küresel refahın artırılması adına oldukça önemlidir. Fakat mevcut literatürde özellikle bu konuda büyük bir eksiklik tespit edilmiştir. Nitekim literatürde daha önce örneklem olarak OECD ülkelerini seçen ve ekonomik göstergelerini baz alarak kümeleme analizi gerçekleştiren kısıtlı sayıda çalışma (Megyesiova & Lieskovska, 2018; Billková, 2019; Suhányi et al., 2021; İşleyen, 2021) mevcuttur. Aynı zamanda bu çalışmalarda (Megyesiova & Lieskovska, 2018; Billková, 2019) tek bir yıl için analiz yapıldığı ve bu nedenle de yıllar itibari ile kapsamlı politika çıkarımlarının yapılamayacağı aşikardır. Farklı yıllar için kümeleme analizi yapan diğer çalışmalar da ise bu çalışmada yer alan makroekonomik değişkenlerin seçilmediği ve özellikle istihdam verileri üzerinde durulduğu belirlenmiştir. Ayrıca bu çalışma karar ağaçları taşımacılık göstergelerine göre sınıflandırma yapılması ile de literatürdeki çalışmalardan farklılaşmaktadır. Öyle ki mevcut literatürde örneklem olarak Avrupa Birliği (AB) üyesi ülkeleri ve Türkiye'yi seçerek hizmet ve sanayi sektörlerinde veya çeşitli endekslere etki eden en önemli değişkenlerin tespit edildiği çalışmalar (Albayrak & Yılmaz, 2009; De Oña et al., 2012; Aytekin, 2019 ve Abreu et al., 2023; Yakut & Korkmaz, 2020; Kutnjak

et al., 2020; Timor & Yüzbaşı Künc, 2021 ve Özkan et al., 2023) bulunmaktadır. Fakat bu çalışmadaki gibi OECD üyesi ülkeler arasında ekonomik gelişme düzeyinin farklılaşmasına sebep olan taşımacılık göstergelerinin belirlendiği hiçbir çalışmaya literatürde rastlanmamıştır. Yine bu çalışmada OECD ülkelerinin ekonomik gelişme düzeylerinde farklılığa sebep olan değişkenlerin ileriye yönelik öngörülerini yapay sinir ağları ile gerçekleştirilerek 2025 yılı projeksiyonu ortaya koyulmuştur. Literatürde yapay sinir ağlarını kullanarak öngörü gerçekleştiren çalışmalarda (Demir & Eminler, 2020; Karakurt & Aydın, 2023) genellikle AB, BRICS (Brezilya, Rusya, Hindistan, Çin ve Güney Afrika) ve MINT (Meksika, Endonezya, Nijerya ve Türkiye) ülkelerinin örneklem olarak seçildiği ve CO₂ salınımına ilişkin değişkenlere odaklanıldığı; örneklem olarak Türkiye'nin seçildiği çalışmalarda (Şen et al., 2021; Özdemir, 2021; Kılınç et al., 2022; Ağbulut, 2022) ise denizcilik değişkenlerinin yer aldığı saptanmıştır. Dolayısı ile literatürde OECD ülkelerinin hem altyapı yatırımlarına hem de havayolu taşımacılığının sebep olduğu CO₂ emisyonlarının yapay sinir ağları ile öngörüsüne odaklanarak 2025 projeksiyonu ortaya koyan hiçbir çalışmaya rastlanmamıştır. Son olarak literatürdeki hiçbir çalışmada OECD ülkelerinin ekonomik gelişme düzeylerinde farklılığa sebep olduğu belirlenen taşımacılık değişkenlerinin ekonomik büyüme üzerindeki etkisinin panel regresyon analizi ile incelenmediği saptanmıştır. OECD ülkelerini örneklem olarak seçen çalışmalarda (Hayaloğlu, 2015; Kabaklarlı et al., 2018) yurtiçi altyapı yatırımlarına ek olarak internet abone sayısı, telefon hatları, işgücüne katılım oranı ve gayrisafi sabit sermaye oluşumu değişkenleri seçilmiştir. Nitekim ile bu çalışmada seçilmiş olan demiryolu altyapı yatırımı, GSYH başına düşen toplam iç ulaşım altyapı yatırımı, kişi başına düşen demiryolu altyapı yatırımı ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payına ait dört adet bağımsız değişken ve GSYH bağımlı değişkeni ile daha önce bir regresyon modeli kurulmadığı tespit edilmiştir. Dolayısı ile mevcut literatürdeki eksikliklerden de anlaşılacağı üzere bu çalışma, dört farklı adımdan oluşan veri madenciliği analizleri ile literatüre teorik katkılar sunacaktır.

Bu çalışmada, içerisinde hem gelişmekte olan hem de gelişmiş ülkelerin yer aldığı OECD ülkelerinin veri tabanlarında biriken büyük veri yığınlarının veri madenciliğine özel algoritmalar kullanılarak analiz edilmesi ve özellikle ekonomik açıdan gelişmek isteyen ülkelerin hangi lojistik göstergeleri iyileştirmeleri gerektiğine dair bir yol haritası sunulması amaçlanmıştır. Çalışmanın amacı doğrultusunda 29 OECD üyesi ülke için

gerçekleştirilen veri madenciliği uygulamaları dört farklı adımdan oluşmuştur. Birinci adımda WEKA 3.8.6 yazılımında k-ortalamlar kümeleme algoritması kullanılarak OECD ülkelerinin GSYH, ihracat, ithalat, enflasyon ve işsizlik oranı değişkenlerinin 2013-2022 dönemlerine ait yıllık verileri ile her yıl için ayrı ayrı kümeleme analizi gerçekleştirilmiştir. Kümeleme analizi sonucunda ülkelerin dört kümeye ayrıldığı belirlenmiştir. Almanya ve Amerika'nın her yıl en gelişmiş ülkeleri barındıran kümede birlikte yer aldığı; Belçika, Fransa, Japonya, Kanada, Kore ve Birleşik Krallık'ın ise gelişmiş ülkelerden oluşan kümede bulundukları tespit edilmiştir. Gelişmekte olan ülkelerin bulunduğu kümede Yunanistan ve İspanya'nın bulunduğu; Türkiye'nin ise özellikle son yıllarda gelişmekte olan ülkelere biri konumunda yer aldığı saptanmıştır. Estonya, Letonya ve Litvanya'nın ise her yıl az gelişmiş ülkeleri temsil eden kümede birlikte yer aldıkları belirlenmiştir. Analizin ikinci adımında, karar ağaçlarında J48 algoritması kullanılarak WEKA 3.8.6 yazılımında sınıflandırma yapılmıştır. Karar ağaçları uygulamasında birinci adımdaki kümeleme analizi sonucunda elde edilen nominal hedef değişkenler ve tahminleyici olarak 29 OECD üyesi ülkeye ait 20 adet taşımacılık değişkeninin 2019 yılına ait nümerik veriler kullanılmıştır. Yapılan analiz sonucunda OECD ülkelerinin ekonomik gelişme düzeylerinde farklılığa sebep olan değişkenlerin demiryolu altyapı yatırımı, GSYH başına düşen toplam iç ulaşım altyapı yatırımı, kişi başına düşen demiryolu altyapı yatırımı ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payı olduğu belirlenmiştir. Ardından analizin üçüncü adımında, 29 OECD üyesi ülkenin her biri için bu dört adet taşımacılık değişkeninin yapay sinir ağları ile 2025 yılına ait öngörüler oluşturulmuştur. Yapılan öngörülerde literatürdeki çalışma (Gosasang et al., 2011; Demir & Eminler, 2020; Şen et al., 2021; Jena et al., 2021; Özdemir, 2021; Kılınç et al., 2022; Ağbulut, 2022; İslam et al., 2022; Mutascu, 2022; Gatarić et al., 2023) sonuçları ile uyumlu şekilde MAPE (Ortalama Mutlak Yüzde Hata-Mean Absolute Percentage Error) değerinin oldukça küçük çıkması yapay sinir ağlarının taşımacılık değişkenlerinin öngörüsündeki başarısını ortaya koymuştur. Son adımda, demiryolu altyapı yatırımlarının, kişi başına düşen demiryolu altyapı yatırımlarının, GSYH başına düşen toplam iç ulaşım altyapı yatırımlarının ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının ekonomik büyümeye etkisi 2010-2019 dönemine ait yıllık veriler kullanılarak Driscoll-Kraay dirençli tahmincisi ile STATA 16 paket programında incelenmiştir. Regresyon analizi neticesinde, demiryolu altyapı yatırımı ve kişi başına düşen demiryolu altyapı yatırımının

GSYH üzerindeki etkisinin istatistiki olarak anlamsız olduđu; GSYH başına düşen toplam iç ulaşım altyapı yatırımı ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının ise GSYH üzerindeki etkisinin istatistiki olarak anlamlı olduđu belirlenmiştir. Çalışma sonucunda, OECD ülkelerinin ekonomi ve lojistik alanlarında biriken büyük veri yığınları içerisinde stratejik öneme sahip bilgilerin açığa çıkarıldığı ve bu sayede özellikle araştırmacılar ve politika yapıcılar için önemli uygulama çıkarımları sunulurken literatürde katkı sağlanacağı düşünülmektedir.



1. BÖLÜM

KÜMELEME ANALİZİ

ÖZET

Günümüzde yaşanan teknoloji devrimi veri tabanlarında büyük miktarda verinin birikmesine sebep olmaktadır. Büyük verinin biriktiği alanlardan biri ise ekonomi alanıdır. Ekonomi alanında biriken büyük verinin içerisinde gizli örüntülerin keşfedilebilmesi için ise veri madenciliği sürecine duyulan ihtiyaç gün geçtikçe artmaktadır. Bu çalışmanın amacı; OECD üyesi ülkeleri ekonomik gelişme düzeylerine göre kümeler ayırmak ve yıllar içerisinde bu kümeler arasında oluşan farklılıkları ortaya koymaktır. Bu amaç doğrultusunda hiyerarşik olmayan veri madenciliği yöntemlerinden k-ortalamlar algoritması kullanılarak 29 OECD üyesi ülkeye ait GSYH, ihracat, ithalat, enflasyon ve işsizlik oranı değişkenleri ile 2013-2022 dönemleri için yıllık veriler ile WEKA yazılımında ayrı ayrı kümeleme analizi gerçekleştirilerek ülkeler dört kümeye ayrılmıştır. Analiz sonucunda Almanya ve ABD'nin en gelişmiş ülkeler; Belçika, Fransa, Japonya, Kanada, Kore ve Birleşik Krallık'ın ise gelişmiş ülkeler oldukları tespit edilmiştir. Gelişmekte olan ülkeleri Yunanistan ve İspanya temsil eder iken; Türkiye'nin son yıllarda gelişmekte olan ülkelere birisi konumuna geldiği görülmüştür. Estonya, Letonya ve Litvanya'nın ise az gelişmiş ülkeleri temsil eden kümede oldukları belirlenmiştir.

Anahtar Sözcükler: Veri madenciliği, Kümeleme analizi, K-ortalamlar, WEKA, OECD.

ABSTRACT

Today's technological development generates an enormous amount of data in databases. One of the areas where large data accumulates is the field of economy. In order to discover the hidden patterns from the big data accumulated in the field of economy, the need for the data mining process is increasing day by day. The purpose of this study is to divide OECD member countries into clusters according to economic development levels and reveal the differences between these clusters over time. For this purpose, the K-sites algorithm of non-hierarchical data mining methods was used by using WEKA software separately in the 2013-2022 periods of GDP, export, import, inflation, and unemployment rate variables of 29 OECD member states. As a result of the analysis, countries are divided into four clusters. In this context, Germany and the US are the most developed countries; Belgium, France, Japan, Canada, Korea, and the United Kingdom were developed countries. Greece and Spain represent developing countries; it has been seen that Turkey has become one of the developing countries in recent years. It was determined that Estonia, Latvia, and Lithuania are in the cluster representing less developed countries.

Keywords: Data Mining, Cluster Analysis, K sites, WEKA, OECD.

GİRİŞ

Günümüzde hızlı bir dijitalleşme süreci yaşanmakta ve teknolojik gelişmeler her gün farklı alanlarda milyarlarca verinin birikmesine sebep olmaktadır. Veri tabanlarında her gün çok yüksek bir hız ile biriken büyük veri yığınlarını yönetmek ve bu veri yığınları içerisinde ihtiyaç duyulan bilgilere ulaşmak ise gittikçe zorlaşmaktadır. Bu kapsamda veri analiz teknikleri kullanılarak büyük veri yığınları içerisinde ihtiyaç duyulan bilgilerin keşfedilmesi büyük önem taşımaktadır. Tam da bu noktada veri madenciliği gelişmiş bir yöntem olarak karşımıza çıkmaktadır. Nitekim veri madenciliği sürecinde istatistiki algoritmalar kullanılarak veri tabanlarından daha önce açığa çıkarılmamış bilgilerin bulunması ve bilgilerin analizi mümkün olmaktadır.

Veri madenciliği süreci büyük verinin bulunduğu her alanda uygulanabilmektedir. Bu alanlardan biri de gün geçtikçe daha fazla büyük verinin biriktiği ekonomi alanıdır. Özellikle ülkelerin ekonomik gelişme düzeylerinin belirlenebilmesinde kullanılan makroekonomik değişkenlerin veri madenciliği sürecinde kullanılan özel algoritmalar yardımı ile analiz edilmesi ve böylelikle makroekonomik değişkenlere ait büyük miktardaki veriden çeşitli kurumlar için stratejik öneme sahip bilgilerin elde edilmesi oldukça önemlidir. Bu kapsamda bu çalışmada veri madenciliği süreci, ülkelerin makroekonomik değişkenlerinin analiz edilerek ülkelerin ekonomik gelişme düzeyinin tespit edilebilmesi için uygulanmıştır.

Literatürde makroekonomik değişkenlerin veri madenciliği yöntemleri kullanılarak analiz edilmesi ile sanayileşmiş ve gelişmekte olan ülkelerden oluşan OECD (Organisation for Economic Co-Operation and Development) (Ekonomik Kalkınma ve İşbirliği Örgütü) üyesi ülkelerin ekonomik gelişme düzeylerinin yıllar içerisindeki değişimini ayrıntılı şekilde analiz eden çalışma sayısı oldukça azdır. Nitekim literatürde ülkelerin ekonomik göstergeleri ile kümeleme analizi gerçekleştiren çalışmalarda örneklem olarak OECD ülkelerini seçen kısıtlı sayıda çalışma (Megyesiova & Lieskovska, 2018; Billková, 2019; Suhányi et al., 2021; İşleyen, 2021) bulunmaktadır. Bu çalışmaların hiçbirinde yalnızca GYSH, ihracat, ithalat, enflasyon ve işsizlik oranı değişkenleri seçilmemiştir. Ayrıca literatürdeki çalışmalarda analizler genellikle SPSS programında gerçekleştirilmiştir. Son olarak literatürdeki çalışmaların çoğu (Megyesiova & Lieskovska, 2018; Billková, 2019; Akkuş & Zontul, 2019; Timor & Yüzbaşı Künc, 2021; Saeed & Cullinane, 2021; Çılgın & Kurt, 2021; Brzyska & Szamrej-Baran, 2021)

tek bir yıl için kümeleme analizi gerçekleştirmiştir. Bu kapsamda bu çalışmanın literatürdeki çalışmalardan farklılaşan çeşitli yönleri bulunmaktadır. Nitekim çalışmada örneklem olarak OECD üyesi ülkelerinin seçilmiş olması, analizlerde GYSH, ihracat, ithalat, enflasyon ve işsizlik oranı değişkenlerinin kullanımı ve analizlerin güçlü bir veri madenciliği yazılımı olan WEKA programında gerçekleştirilmesi yönleri ile bu çalışmanın literatüre katkı sunması beklenmektedir. Bunlara ek olarak literatürün aksine on yıllık bir zaman periyodu için kümeleme analizinin gerçekleştirilmiş olmasının da ülkelerin ekonomik gelişmişliklerinde yaşanan değişimin daha ayrıntılı şekilde yorumlanabilmesine olanak sağladığı söylenebilir. Bu doğrultuda on yıllık bir zaman periyodunda ülkelerin ekonomik gelişmişliklerinin değişimine ilişkin ayrıntılı sonuçlar sunan bu çalışmanın literatüre katkı sağlayacağı ve OECD ülkelerinde ekonomik gelişmenin sağlanabilmesi adına verilen önerilerin politika uygulayıcılara fikir vereceği düşünülmektedir. Bu kapsamda bu çalışmanın amacı; OECD üyesi ülkeleri ekonomik gelişme düzeylerine göre kümelere ayırmak ve yıllar içerisinde bu kümeler arasında oluşan farklılıkları ortaya koymaktır. Bu amaç doğrultusunda bu çalışmada, hiyerarşik olmayan veri madenciliği yöntemlerinden k-ortalamalar algoritması kullanılarak 29 OECD üyesi ülkeye ait 5 adet makroekonomik değişken ile 2013-2022 dönemleri için yıllık veriler ile WEKA yazılımında ayrı ayrı kümeleme analizi gerçekleştirilmiştir. Böylelikle ülkeler çok gelişmiş, gelişmiş, gelişmekte olan ve az gelişmiş olmak üzere dört kümeye ayrılmıştır. Analiz sonucunda; Almanya ve ABD'nin de çok gelişmiş ülkeleri temsil eden küme 1'de yer aldıkları belirlenmiştir. Küme 3 ise; 2017 ve 2018 yılı haricinde her zaman gelişmiş ülkeleri temsil etmiş ve bu kümede Belçika, Fransa, Japonya, Kanada, Kore ve Birleşik Krallık yer almıştır. Yunanistan ve İspanya'nın her yıl gelişmekte olan ülkeleri temsil eden küme 0'da yer aldığı tespit edilirken; Türkiye'nin de son iki yıldır bu kümede yer aldığı saptanmıştır. Estonya, Letonya, Litvanya'nın ise 2018 yılı haricinde her yıl küme 2'de az gelişmiş ülkeler olarak yer aldıkları görülmüştür.

1.1. Literatür taraması

Literatürde makroekonomik değişkenler kullanılarak kümeleme analizi yapılan bazı çalışmalar Tablo 1.1.'de gösterilmiştir. Tablo 1.1. incelendiğinde; genellikle Avrupa Birliği'ne üye ülkeler ve OECD üyesi ülkelerin örneklem olarak seçildiği tespit edilirken; analizlerin çoğunlukla GSYH, işsizlik oranı, enflasyon oranı, ücret göstergeleri, ihracat, ithalat değişkenleri ile çeşitli endeksler kullanılarak gerçekleştirildiği saptanmıştır. Aynı zamanda literatürde yer alan çalışmalarda çoğunlukla kümeleme analizi tekniklerinden

hiyerarşik olmayan yöntemler içerisinde yer alan K-Ortalamlar tekniği tercih edilmekle birlikte Ward Methodu, Kendi Kendini Düzenleyen Haritalar Yöntemleri ve Rastgele Orman Sınıflandırma Modeli tekniklerinin de kullanıldığı belirlenmiştir.

Tablo 1.1. Kümeleme Analizi Yapılan Çalışmalar

Yazar-Yıl	Çalışmanın Başlığı	Veriler	Yöntem	Bulgular
(Megyesiova & Lieskovska, 2018).	Analysis of the sustainable development indicators in the OECD countries.	2000 ve 2008 yıllarına ait kişi başına GSYH başta olmak üzere toplamda 15 adet değişken analize tabi tutulmuştur.	Kümeleme analizi.	2000 yılı sonrası verilerine göre Türkiye'nin Şili, Güney Kore ve Meksika ile birlikte yer aldığı kümede kişi başına düşen GSYH değerinin çok düşük olduğu saptanmıştır. 2008 yılı sonrası için yapılan analizde ise Türkiye'nin Şili ve Güney Kore ile aynı kümede yer aldığı tespit edilmiştir.
(Yüzbaşı Künc, 2018).	Avrupa Birliği ülkeleri ve Türkiye'nin 2013-2017 yıllarına ait ekonomik göstergelerinin kümeleme analizi ile değerlendirilmesi.	Avrupa Birliği'ne üye ülkeler ile Türkiye'nin 2013-2017 yıllarına ait GSYH, ihracat/ithalat oranı ve işsizlik oranı verileri kullanılmıştır.	K-Ortalamlar kümeleme metodu.	Yıllar içerisinde İspanya ve İtalya'nın ekonomik açıdan daha düşük seviyedeki ülkeler ile aynı grupta yer aldığı tespit edilmiştir.
(Billková, 2019).	Assessment of living standard indicators in the OECD member countries.	Türkiye ve Litvanya haricindeki OECD üyesi ülkeler 2016 yılına ait kişi başına düşen GSYH, işsizlik oranları, döviz ve enflasyon oranları, ortalama ücret, asgari ücret, gelir vergisi, çalışılan saat başına GSYH, sanayi, inşaat ve imalat endeksleri dikkate alınarak gruplandırılmıştır.	Ward Method.	Amerika Birleşik Devletleri, Almanya, İngiltere, Avustralya, Belçika, Kanada ve Hollanda hep aynı kümede yer alır iken; Yunanistan, İtalya, Portekiz ve İspanya'da her zaman aynı kümede yer almıştır. İrlanda ve Lüksemburg'un ise her zaman kendi gruplarını oluşturdukları belirlenmiştir.
(Akkuş & Zontul, 2019).	Veri madenciliği yöntemleri ile ülkeleri gelişmişlik ölçütlerine göre kümeleme üzerine bir uygulama	214 ülkeye ait 2015 yılı verileri kullanılmıştır. 12 farklı değişken analize tabi tutulmuştur.	Self Organizing Map ve K-Ortalamlar kümeleme	Türkiye'nin daha çok Orta Doğu ülkelerinden oluşan bir kümede yer aldığı tespit edilmiştir.
(Aker & Aghaei I, 2019).	Comparison of business environments in oil-rich MENA countries: a clustering analysis of economic diversification and performance	11 adet MENA ülkesine ait 2010-2016 yılları arasındaki veriler kullanılmıştır. Bunlar: İşsizlik oranı, kişi başına düşen GSYH, mal ve hizmet ihracatı, ham petrol ihracatıdır.	K-ortalamlar yöntemi.	Ülkeler dört kümeye ayrılmıştır. Katar ve Birleşik Arap Emirlikleri'nin en yüksek ekonomik çeşitliliğe, performansa ve bölgedeki en uygun iş ortamlarına sahip oldukları görülmüştür.

(Demirkale Ö & Özari Ç, 2020).	K-ortalamalar kümeleme yöntemi ile temel makroekonomik ve finansal göstergeler ile değerlendirilmesi: kırılmalı beşli ülkelerinin örneği	Beş ülke için 01/2005-06/2019 dönemi aylık verileri kullanılmıştır. Ülkeler ve pay senedi piyasası göstergesi olarak borsa endeks bilgileri, döviz kuru, faiz ve enflasyon oranı; Türkiye için yapılan analizde ise BIST100 endeksi, 1 yıllık tahvil faizinin aylık faiz oranı, Dolar/TL ve Euro/TL döviz kuru değişkenleri kullanılmıştır.	K-ortalamalar kümeleme yöntemi.	Brezilya ve Türkiye'nin çoğunlukla aynı grupta yer aldığı saptanmıştır.
(Suhányi et al., 2021).	Relations between the inflow of foreign direct investments and economic indicators in OECD countries	36 adet OECD üyesi ülkenin 2005-2019 yılları arasındaki istihdam göstergeleri, ücret göstergeleri, ihracat, ithalat, GSHY ve doğrudan yabancı yatırımlara ait veriler kullanılarak ülkeler kümeleme analizi sonucunda 4 kümeye ayrılmıştır.	K-Ortalamlar kümeleme yöntemi.	İrlanda ve Lüksemburg tek başlarına birer kümede yer alır iken Türkiye; Şili, Çek Cumhuriyeti, Estonya, Yunanistan, Macaristan, Japonya, Kore, Letonya, Litvanya, Meksika, Yeni Zelanda, Polonya, Portekiz, Slovak Cumhuriyeti ve Slovenya ile aynı kümede yer almıştır.
(İşleyen, 2021).	Clustering Analysis of Employment Sectors According To OECD Countries Using The K-Average Method.	36 adet OECD üyesi ülkenin 1991-2019 yılları arasındaki istihdam verileri kullanılmıştır.	K-ortalamalar kümeleme yöntemi.	Türkiye'nin tarım sektöründe istihdamın yüksek olduğu ülkeler ile yer alışı tespit edilmiştir.
(Timor & Yüzbaşı Künc, 2021).	Ekonomik Gelişmişliği Etkileyen Bilgi Ekonomisi Değişkenlerinin Veri Madenciliği İle Belirlenmesi	34 Avrupa Birliği üye ülkesi ve Türkiye'nin işsizlik, GSYH ve ihracat ithalat oranı verileri ve 34 bilgi ekonomisi değişkeni kullanılmıştır.	K-ortalamalar kümeleme yöntemi ve karar ağaçları C5.0 algoritması.	Düşük, orta ve yüksek olarak 3 farklı ekonomik seviye grubu elde edilmiştir. Türkiye, Bulgaristan, Çek Cumhuriyeti, Estonya, Yunanistan, İspanya, Hırvatistan, İtalya, Kıbrıs, Letonya, Litvanya, Makedonya, Malta, Polonya, Portekiz, Romanya, Slovenya, Slovakya, Karadağ, Yugoslavya ve Sırbistan ile aynı kümede yer almıştır.
(Saeed & Cullinane, 2021).	Identifying The Characteristics of China's Maritime Trading Partners on The Basis of Bilateral	Çin, Singapur ve Hong Kong'un 155 ticaret ortağının Lojistik Performans Endeksi verileri ile ihracat ve	Hiyerarşik kümeleme analizi ve lojistik regresyon analizi.	Ülkelerin doğrudan deniz bağlantısının bulunmasının önemi ortaya çıkmış ve lojistik performansın ihracat

	Shipping Connectivity: A Cluster Analysis	ithalata ilişkin 2016 yılı verileri kullanılmıştır.		ile ithalat üzerinde olumlu etkisi olduğu saptanmıştır.
(Çılgın & Kurt, 2021).	Dış Ticaret Verileri İçin Kümeleme Analizi: Türkiye, Azerbaycan ve Kazakistan Örneği	3 ayrı ülke için 2017 yılına ait ihracat, ithalat, nüfus, GSYH ve coğrafi uzaklıklar analize dahil edilmiştir.	K-ortalamalar, Ward ve Kendi Kendini Düzenleyen Haritalar yöntemleri.	Türkiye'nin ihracat verileri için yapılan kümeleme analizine göre ülkeler sekiz kümeye ayrılırken, ithalat verilerinin analizinde ülkeler dokuz kümeye ayrılmıştır.
(Brzyska & Szamrej-Baran, 2021).	Classification of the EU Countries According to the Vulnerability of their Economies to the Impact of COVID-19 Pandemic.	27 Avrupa Birliği ülkesine ait 17 adet değişken kullanılmıştır.	K-ortalamalar ve Ward yöntemi	Ülkelerin 4 kümeye ayrıldığı tespit edilmiştir. Covid-19 pandemisinin Almanya, Hollanda, İrlanda ve İskandinav ülkelerinin ekonomileri üzerindeki etkisinin az olduğu belirlenmiştir.
(Grădinaru & Maricuț, 2022).	From The Rebound Effect To The Perspective of Circular Economy: A Structure Changes Analysis Among EU Countries	Avrupa Birliği Ülkeleri'ne ait 2000-2019 yılları arasındaki veriler kullanılmıştır. 5 adet değişken vardır: Yerli kaynaklar, malzeme ithalat bağımlılığı, kaynak verimliliği, toplam çevre vergileri, GSYH.	K-ortalamalar ve Rastgele Orman Sınıflandırma Modeli	Romanya'nın her iki yöntemde de ikinci kümede yer aldığı saptanmıştır.
(Marčeta & Boinec, 2022).	Analysis of the economic performance and competitiveness of the European Union countries.	28 AB üyesi ülkenin 2008-2015 ve 2015-2019 yılları arasındaki verileri kullanılmıştır. İhracat hacmi, ithalat hacmi, ihracatın GSYH içerisindeki payı ve kişi başına düşen GSYH endeksi kullanılmıştır.	Ward yöntemi.	2015-2019 döneminde ilk benzer grupta Portekiz, İtalya, İrlanda, Yunanistan, Kıbrıs, Malta, Litvanya, Polonya, Slovenya, Romanya, Slovakya, Çek Cumhuriyeti, Estonya, Letonya, Macaristan, Bulgaristan ve Hırvatistan yer alırken; 2. Benzer grupta Belçika, Avusturya, İspanya, İtalya, Finlandiya, Almanya, Fransa, Danimarka, İsveç, Hollanda, Lüksemburg ve İngiltere'nin yer aldığı belirlenmiştir.

1.2. Araştırma Metodolojisi ve Veri Seti

1.2.1. Büyük verinin kavramsal olarak ortaya çıkışı ve özellikleri

Büyük veri kavramı ilk kez ilk kez 1997 yılında düzenlenen 8. IEEE Görüntüleme Konferansı'nda (Proceedings of the 8th Conference on Visualization), Michael Cox ve

David Ellsworth tarafından “Application Controlled Demand Paging for Out-of-core Visualization” isimli makalede kullanılmıştır (Cox & Ellsworth, 1997: 235). Büyük veri kavramının telaffuzu her ne kadar yakın geçmişte gerçekleşmiş olsa da aslında büyük miktarda verinin toplanarak saklanması 1950’li yılların başına kadar uzanmaktadır. Fakat 1990’lı yıllarda dünya çapında ağın (www.) ortaya çıkmasına kadarki dönemde veri depolamadaki yüksek maliyetin varlığı verilerin yavaş büyümesine neden olmuştur (Lee, 2017: 4). Günümüzde içerisinde bulunduğumuz bilgi çağının da etkisi ile her alanda verinin birikme hızı sürekli olarak artmaktadır. Öyle ki günümüzde yaşanan teknoloji devrimi ile petabayt çağı neredeyse bitmek üzeredir ve artık eksabayt çağı ile yüzleşilmesi gerekmektedir (Che et al., 2013: 1). Çünkü veri; okullarda, hastanelerde, kamuda, özel şirketlerde, sosyal ağlarda yani kısacası her yerdedir (Khan et al., 2014: 1). Fakat büyük verinin asıl kaynağının her saniye veri üreten mobil cihazlar ve sosyal medya olduğu söylenebilir (Jamil et al., 2018: 229).

Büyük veri kısaca büyük veri kümesi olarak tanımlanır (Khan et al., 2014: 1). Büyük veri, sayısız sistemde saklanan milyonlarca hatta trilyonlarca kullanıcıya ait bilgileri içerir (Sowmya & Suneetha, 2017: 246). Bir başka tanıma göre ise büyük veri; geleneksel veri işleme araçları kullanılarak yönetilmesi ve analiz edilmesi mümkün olmayan devasa büyüklüklere ulaşmış veri kümeleridir (Ohlhorst, 2012: 1; Taylor-Sakyi, 2016: 1). Yüksek hızlı, büyük hacimli bir veri seti olan büyük veri; iyi bir süreç optimizasyonunu, kuralların keşfini ve karar vermeyi ileri teknolojiler ve yeni algoritmalar kullanarak gerçekleştirebilir (Pilipczuk et al., 2019: 10). Farklı tanımlardan da görülebileceği gibi büyük veri denildiğinde akla ilk olarak verinin boyutu gelmektedir. Aslında kullanılan büyük veri teriminin verinin yalnızca boyutuna dikkat çektiği ve diğer özelliklerine işaret etmediği için yanlış bir ifade olduğu söylenebilir (Katal et al., 2013: 4040). Bu bağlamda Laney (2001) büyük verinin özelliklerini 3V olarak da bilinen volume (hacim), velocity (hız) ve variety (çeşitlilik) olarak belirtmiştir. Ohlhorst (2012), ise büyük verinin temel özelliklerini volume (hacim), velocity (hız) ve variety (çeşitlilik) ve veracity (doğruluk) olmak üzere 4V olarak ifade etmiştir. Khan et al., (2014) ise büyük verinin özelliklerini 7V olduğuna işaret etmiştir. Bunlar: volume (hacim), velocity (hız), variety (çeşitlilik), veracity (doğruluk), validity (geçerlik), volatility (oynaklık) ve value (değer) olarak karşımıza çıkmaktadır. Bu özelliklere ek olarak büyük verinin complexity (karmaşıklık) özelliğine de sahip olduğu söylenebilir. (Katal et al., 2013: 404; Lee, 2017: 2).

1.2.2. Büyük verinin analizinde veri madenciliğinin kullanımı

Günümüzde internetin keşfi bilgiye ulaşmayı kolay hale getirmiş gibi gözükse de aslında ihtiyaç duyulan bilginin büyük veri yığınları arasından bulunarak açığa çıkarılmasını güçleştirmiştir (Cemaloğlu & Duykuluoğlu, 2020: 1). Çünkü hızla gelişen dünyada her gün çeşitli bilim alanlarında çok büyük miktarda veri toplanmakta ve bunlar hızlı bir şekilde birikmektedir (Fayyad et al., 1996: 82; Han et al., 2012: 1). Öyle ki bilgisayar kullanımının yaygınlaşması ve uygun fiyatlı depolama alanlarının varlığı hükümetlerin, işletmelerin ve araştırma kurumlarının veri tabanlarında çok büyük ölçekli veri yığınlarının birikmesine sebep olmuştur (Pujari, 2001: 1). Birkaç yıl öncesine kadar terabayt büyük bir veri tabanı olarak kabul edilirken bugün veri tabanları petabayt ve eksabayt cinsindedir. Bu durum veri tabanlarının akıl almaz şekilde büyüdüğünü göstermektedir (Maheshwari, 2015: 9). Her alanda verinin bu denli hızlı şekilde birikmesi bu veri setini yönetmeyi ve ondan değer elde etmeyi de zorlaştırmıştır (Ohlhorst, 2012: 1). Büyük miktarda ve yüksek boyuttaki karmaşık verilerin işlenmesi için veri madenciliği zorunlu hale gelmiştir (Ersöz, 2019: 16).

Her gün büyük bir hızla biriken veriler özellikle iş dünyasını etkilemektedir. Günümüzde veri tabanlarında çok büyük miktarda veri olmasına rağmen yeterli bilginin olmaması işletmelerin karşılaştığı en büyük sorunlardan biri olarak karşımıza çıkmaktadır. Bu nedenle veri tabanlarında biriken büyük veri yığınları içerisinde işletmeler ve kurumlar için yararlı bilgilerin veri analiz teknikleri kullanılarak bulunması ve ortaya çıkarılması gerekmektedir. İşte bu noktada veri madenciliği kavramı devreye girer. Veri madenciliği, veri tabanlarında biriken verilerin analiz edilerek, gizli kalıpların açığa çıkarılması ve sorunların çözülmesi ile ilgili bir kavramdır (Witten et al., 2016: 3-4). Gelişmiş ve etkili bir yöntem olarak karşımıza çıkan veri madenciliği, kurumsal veri tabanlarında yer alan verileri ortaya çıkararak örgütsel amaçlar doğrultusunda kararlar alınmasına yardımcı olmaktadır (Wu et al., 2012: 68).

1.2.3. Veri madenciliği

Disiplinler arası bir çalışma alanı olan veri madenciliği istatistik, makine öğrenme ve veri tabanları alanlarından yararlanılarak ortaya çıkarılan bir veri toplama yöntemidir (Holsheimer vd., 1995: 150). Verileri ayıklamak için özel algoritmalar kullanılması veri madenciliği olarak adlandırılmaktadır (Fayyad, Piatetsky-Shapiro ve Smyth, 1996: 39). Veri madenciliği faydalı kalıpların ve yeni eğilimlerin büyük veri kümelerinden

keşfedilmesi sürecidir (Larose & Larose, 2014: 2). Veri madenciliği süreci verilerdeki yeni, anlaşılabilir ve yararlı kalıpların belirlenmesidir (Pujari, 2001: 39). Veri madenciliği bilgi keşif sürecinin bir parçası olmakla birlikte istatistiksel algoritmaları kullanarak verilerdeki gizli örüntüleri ve bilgileri keşfederek açığa çıkarılmasını sağlar (Rygielski et al., 2002: 485). Kısacası veri madenciliği, çeşitli yöntemler kullanılarak değeri olan bilginin su yüzüne çıkartılmasıdır (Özkan, 2020: 12). Literatürde veri madenciliği sürecine ilişkin tanımların ortak noktası; özel analiz algoritmalarının kullanılıyor olması ve böylelikle gerçekten yararlı olan bilgilerin büyük veri yığınları arasından açığa çıkarılabilmesidir.

Veri tabanlarından daha önce ortaya çıkarılamamış ilgi çekici veya değerli bilgilerin ortaya çıkarılmasını ve analizini mümkün kılan veri madenciliği birincil amacı ise açıklama ve tahmin yapmaktır (Fayyad et al., 1996: 44; (Mints, 2017: 48). Bahsedilen amaçları gerçekleştirmek üzere ise veri madenciliğinin; betimleyici (tanımlayıcı) ve tahmin edici olmak üzere iki temel yöntemi vardır (Akpınar, 2000: 5; Albayrak & Koltan Yılmaz, 2009: 33; Mints, 2017: 48; Cemaloğlu & Duykuluoğlu, 2020: 98). Sınıflandırma ve regresyondan oluşan tahmin edici yöntemler denetimli öğrenme işlevine sahip olup hedef değeri tahmin etmeye yarar iken; kümeleme ve ilişkilendirme analizlerinden oluşan betimleyici (tanımlayıcı) yöntemler denetimsiz öğrenme işlevine sahip olup daha çok verilerin iç yapısına ve veriler arası ilişkilere odaklanmaktadır (Taft et al., 2003: 31-45). Araştırmacılar açıklama veya tahmin yapma amaçlarına uygun olarak veri madenciliği yöntemlerinden tanımlayıcı veya tahmin edici yöntemleri kullanabilirler. Bu çalışmanın amacına uygun olarak veri madenciliği yöntemlerinden tanımlayıcı yöntemler içerisinde yer alan kümeleme analizi tercih edilmiştir.


1.2.4. Kümeleme analizi

Veri madenciliği sürecindeki temel yöntemlerden biri kümeleme analizidir (Williams, 2011: 179). Kümeleme analizi veri madenciliğinde tanımlayıcı yöntemler içerisinde yer almaktadır ve denetimsiz öğrenme (Unsupervised Learning) işlevine sahiptir. Bu algoritma 1967 yılında J.B. MacQueen tarafından geliştirilmiştir (MacQueen, 1967: 281-297). Oldukça yaygın olarak kullanılan k-ortalamalar yöntemi, ‘n’ birimin ‘k’ sayıda kümeye ayrılmasını hedef alır (Han et al., 2012: 451; Özkan, 2020: 209). Merkez nokta, kümeyi temsil etmekle birlikte her veri sadece tek bir kümeye atanmaktadır. Böylelikle bu yöntemle birlikte eşit büyüklükteki küresel kümeler tespit edilmektedir (Işık & Çamurcu, 2007: 32). Kümeleme analizi ile benzer özelliklere sahip

nesnelerin kümelenmesi gerçekleştirilir (Ramageri, 2010: 302). Başka bir tanıma göre ise kümeleme analizi, veri setini veya gözlemleri alt kümelere ayırma işlemidir. Her alt küme öyle bir kümedir ki bu alt kümede bulunan veriler veya gözlemler birbirine benzerlerken diğer alt kümedekilere benzemezler (Han et al., 2012: 444; Larose & Larose, 2014: 12; Maheshwari, 2015: 101).

Kümeleme analizinde verilerin sınıfları daha önceden belli değildir ve veriler nispeten homojen kümelere ayrılmaktadırlar (Collier et al., 1998: 21; Akpınar, 2000: 6; Larose & Larose, 2014: 209-210; Maheshwari, 2015: 99; Mints, 2017: 48-49; Ersöz, 2019: 77-78; Takçı, 2020: 151- 152). Bunun için ise veriler arasındaki uzaklıklar hesaplanır ve böylelikle kümeleme analizinde birbirine benzer veriler aynı küme içerisinde yer alır. Bu kapsamda küme, birbirine yakın olan verilerin oluşturduğu bir gruptur. Kümeleme analizinde uzaklık hesaplamasında kullanılan yöntemler ise; Öklid uzaklığı, Manhattan uzaklığı ve Minkowski uzaklığıdır (Ersöz, 2019: 80; Özkan, 2020: 191). Öklid uzaklığı, en sezgisel ölçüdür (Maheshwari, 2015: 102) ve kümeleme analizinde en çok kullanılan uzaklık hesaplama yöntemidir (Cemaloğlu & Duykuluoğlu, 2020: 157; Özkan, 2020: 193). Kümelerde yer alan verilerin benzerlik ve farklılık düzeyleri için karar verilmesinde kullanılan bir ölçüdür (Han et al., 2012: 553). Öklid uzaklığı, aynı koordinatlar arasındaki farklarının karekökünün alınması ile hesaplanır (Ersöz, 2019: 81). Uzaklık hesaplamasında kullanılan bir diğer popüler ölçü Manhattan uzaklığıdır. Hedef düğüm ile mevcut düğüm arasındaki yatay ve dikey mesafeler toplanarak bulunur (Ersöz, 2019: 81). Kısacası gözlemler arasındaki mutlak uzaklıklar toplanarak bulunur (Özkan, 2020: 193). Amacı, kümede yer alan veriler arasındaki benzerliklerin ortaya çıkarılmasıdır (Cemaloğlu & Duykuluoğlu, 2020: 158). Minkowski uzaklığı ise Öklid uzaklığı ve Manhattan uzaklığının kapsamalarının genişletilmesi ile ortaya çıkmıştır (Cemaloğlu & Duykuluoğlu, 2020: 159). “p” kadar değişken göz önüne alınır ve gözlemler arasındaki uzaklık hesaplanır (Özkan, 2020: 193). Aynı diğer uzaklık ölçütleri gibi veriler arasında var olan benzerliğin ortaya çıkarılmasında kullanılmaktadır (Han et al., 2012: 72).

Kümeleme analizi için farklı algoritmalar geliştirilmiş ve bunlar iki başlık altında toplanmıştır. Kümeleme teknikleri hiyerarşik ve hiyerarşik olmayan yöntemler olarak ikiye ayrılır (Pujari et al., 2001: 20). Hangi tekniğin tercih edileceği ise küme sayısına bağlıdır (Koldere Akın, 2022: 5). Hiyerarşik ve hiyerarşik olmayan kümeleme yöntemleri Şekil 1.1’de gösterilmiştir.



Şekil 1.1. Kümeleme Teknikleri (Grabmeier & Rudolph, 2002: 340).

Hiyerarşik kümeleme yöntemleri, araştırmacının verilerin kaç kümeye ayrılacağına dair bir bilgisi yok ise tercih edilir (Takçı, 2020: 153). Hiyerarşik kümeleme yöntemlerinde öncelikle kümeler bir ana küme olarak ele alınabilir ve ardından bu ana küme aşamalı olarak içerdiği alt kümelere ayrılabilir. Buna ek olarak önce ayrı ayrı olarak ele alınan kümelerin aşamalı olarak birleştirilmesi ve bir küme haline getirilmesi de söz konusudur (Larose & Larose, 2014: 212; Özkan, 2020: 196). Kısacası kümeler aşamalı olarak ayrışabilir veya birleşebilir (Takçı, 2020: 153). Hiyerarşik kümelemenin görselleştirilmesinde dendogram adı verilen ağaç benzeri yapılardan yararlanılır (Han et al., 2012: 457-460; Larose & Larose, 2014: 212; Takçı, 2020: 153).

Küme sayısının ne olacağı hakkında bir bilgi bulunuyor veya araştırmacı küme sayısının ne olması gerektiğine karar vermiş ise hiyerarşik olmayan yöntemler tercih edilir (Turanli et al., 2006: 99; Koldere Akın, 2022: 11). Hiyerarşik olmayan yöntemler, hiyerarşik yöntemlere göre daha hızlıdır. Fakat hiyerarşik yöntemlerin aksine küme sayısının (k) araştırmacı tarafından keyfi seçilmesi veya önceden belli olmasının bir dezavantaj yarattığı unutulmamalıdır (Han et al., 2012: 451; Maheshwari, 2015: 110-111).

1.2.5. Veri seti ve veri dönüşümü

Veri madenciliği, bilgileri işlemeye yönelik bir süreç olarak karşımıza çıkmaktadır (Cemaloğlu & Duykuluoğlu, 2020: 25). Veri madenciliği, birbiri ile bağlantılı süreçlerden meydana gelir. Birbiri ile bağlantılı süreçlerin uygulanması ile birlikte ortaya anlaşılır,

geçerli ve yeni bir sonuç çıkması beklenir. (Zaki & Wong, 2003: 2). İstenilen sonuca ulaşılabilmesi için bilgileri işlemeye yönelik bu süreçte yer alan adımların doğru ve eksiksiz bir şekilde uygulanması gerekir. Aksi takdirde araştırmacı istenilen sonuçlara ulaşmayacaktır (Tekerek, 2011: 162). Bu kapsamda, bu çalışmada veri madenciliği süreci titizlikle ele alınmış ve süreçte yer alan adımlar sırası ile uygulanmıştır. Öncelikle analizlerde kullanılacak veri setine ilişkin hazırlıklar yapılmış ardından da model kurularak kümeleme analizi gerçekleştirilmiştir.

Veri madenciliği ikincil veri analizi ile ilgilidir (Hand, 1998: 112). Bu nedenle çalışmanın uygulama bölümünde ikincil veriler kullanılmıştır. Bu doğrultuda çalışmanın amacına uygun olarak literatürde makroekonomik değişkenlere göre yapılan kümeleme analizlerinde kullanılan değişkenler dikkate alınmış ve 5 adet makroekonomik değişken ile kümeleme analizinin gerçekleştirilmesine karar verilmiştir. Verilerinde eksiklik bulunmayan OECD üyesi 29 adet ülkenin 2013-2022 dönemlerine ait verileri yıllık olarak <https://stats.oecd.org/> web sitesinden 4 Haziran 2023-10 Haziran 2023 tarihleri arasında elde edilmiştir. Japonya'ya ait işsizlik oranı değişkeninin 2021 ve 2022 yıllarına ait verilerinde eksiklik tespit edildiği için ise ilgili yıllara ilişkin veriler <https://data.worldbank.org/> adresinden elde edilmiştir. Modelde kullanılan değişkenler Tablo 1.2.'de ve modelin kurulabilmesi için seçilen ülkeler de Tablo 1.3.'de gösterilmiştir.

Tablo 1.2. Kümeleme Analizi İçin Seçilen Değişkenlere Ait Bilgiler

Değişkenler	Birim
GSHY	Dolar (\$)
İhracat (Mevsimsel etkiden arındırılmış)	Dolar (\$)
İthalat (Mevsimsel etkiden arındırılmış)	Dolar (\$)
Tüketici Fiyatları, Yıllık Enflasyon (Bir önceki yılın aynı dönemine göre)	Yüzde (%)
İşsizlik Oranı (15-64 yaş)	Yüzde (%)

Tablo 1.3. Kümeleme Analizi İçin Seçilen OECD Üyesi Ülkeler

Avusturalya	Çek Cumhuriyeti	Almanya	İtalya
Avusturya	Estonya	Yunanistan	Japonya
Belçika	Finlandiya	Macaristan	Kore
Kanada	Fransa	İrlanda	Letonya
Litvanya	Lüksemburg	Meksika	Yeni Zelanda
Norveç	Polonya	Slovenya	İspanya
İsveç	İsviçre	Türkiye	Birleşik Krallık
Amerika			

Modelin kurularak kümeleme analizinin gerçekleştirilebilmesi için çeşitli kaynaklardan elde edilen 1450 adet veri uygun formlara dönüştürülmüştür. Verilerin

genelleştirilmesi, düzleştirme, yumuşatma, öznitelik oluşturma ve verilerin normalleştirilmesi kısacası verilerin uygun formalara dönüştürülmesi veri dönüşümünü ifade etmektedir (Han et al., 2012: 112; Shalabi et al., 2006: 735). Verilerin normalize edilmesi veri madenciliği yöntemlerinden özellikle en yakın komşu, kümeleme ve yapay sinir ağları algoritmaları için oldukça yararlıdır. Çünkü verilerin normalleştirilmesi ile her bir özneliğe eşit ağırlık verilmeye çalışılır ve normalleştirme işlemi öğrenme süresinin kısalmasını sağlar (Han et al., 2012: 113-114). Bu çalışmada yapay sinir ağlarında en iyi sonucu veren (Yavuz & Deveci, 2012) D_min_max yöntemi uygulanmıştır. Buna göre verilerin [0,1-0,9] değerleri arasına indirgenebilmesi için Eşitlik 1.1'den yararlanılmıştır:

$$x' = 0.8 * \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0.1 \quad (1.1)$$

Eşitlik 1.1'de;

x' = Normalize edilmiş veri,

x_i = Girdi değeri,

x_{min} = Girdi seti içindeki en küçük değer,

x_{max} = Girdi seti içindeki en büyük değerdir.

Verilerin dönüştürülmesinden sonra modelin kurularak analizlerin gerçekleştirilmesinde normalize edilmiş veriler kullanılmıştır.

1.3. Uygulama ve Bulgular

1.3.1 Kümeleme analizinin uygulanması ve bulgular

Bu çalışmada OECD üyesi olan 29 adet ülkeye ait 5 adet makroekonomik değişken ile 2013-2022 tarihleri arasında her yıl için ayrı ayrı kümeleme analizinin gerçekleştirilerek ülkelerin ekonomik gelişmişliklerine göre kümelere ayrılabilmesi için veri madenciliği yöntemlerinden hiyerarşik olmayan yöntemler içerisinde yer alan k-ortalamalar algoritması tercih edilmiştir. Bunun nedeni; k-ortalamalar kümeleme algoritmasının anlaşılmasının ve uygulanmasının kolay oluşudur. Anlaşılma ve uygulama kolaylığının yanında verimli bir yöntem de olan k-ortalamalar algoritmasının kümeleme algoritmaları içerisinde performansı en iyi olan algoritma olduğu da söylenebilir (Haykin, 2009: 244; Maheshwari, 2015: 110). K-ortalamalar algoritması ile kümeleme analizinin

gerçekleştirilmesi için ise Yeni Zelanda'daki Waikato Üniversitesi tarafından geliştirilen ve popüler bir veri madenciliği yazılımı olan Weka 3.8.6 kullanılmıştır. Çünkü Weka, veri madenciliği sürecinde ücretsiz olarak kullanılabilen açık kaynak kodlu bir yazılımdır (Maheshwari, 2015: 55; Bramer, 2020: 506) ve veri hazırlama, regresyon, sınıflandırma, kümeleme, birliktelik kuralları ile veri görselleştirme gibi veri madenciliği görevlerini kolayca yerine getirebilmektedir (<https://www.cs.waikato.ac.nz/ml/weka/> Erişim tarihi: 12.03.2023). Bu doğrultuda en kapsamlı ve en güçlü veri madenciliği yazılımlardan biri olduğu söylenebilir (Kaya & Özel, 2014: 50).

Weka 3.8.6 yazılımında k-ortalamlar kümeleme yöntemini uygulamak için izlenen adımlar ise şunlardır (Larose & Larose, 2014: 215):


1. Araştırmacı tarafından küme sayısının (k) kaç olacağı belirlenmelidir.
2. Başlangıç küme merkezleri için rastgele veri seçilir.
3. Her bir veri için en yakın küme merkezi tespit edilir. Böylelikle veriler küme merkezi kendisine en yakın olan kümelere atanır.
4. Tüm verilerin ataması tamamlandığında küme ortalamaları hesaplanır ve “k” adet küme merkezinin boyutları yeniden hesaplanır.
5. Küme elemanları sabitleninceye kadar adım 3 ve adım 4 tekrarlanır.

Beş adımdan oluşan k-ortalamlar kümeleme yönteminin uygulanabilmesi için öncelikle küme sayısının (k) belirlenmesi gereklidir. Küme sayısı, araştırmacı tarafından keyfi olarak belirlenebileceği gibi bu durumun dezavantaj yaratabileceği de bir gerçektir. Bu dezavantajın ortadan kaldırılabilmesi için literatürde küme sayısının belirlenmesine ilişkin formüller mevcuttur. Bu formüller yardımı ile de küme sayısı belirlenebilmektedir. Pratik olarak “n” örneklem sayısı ve “k” küme sayısı olmak üzere (1.2) numaralı denklem sıklıkla tercih edilmektedir (Everitt, 1974: 122):

$$k \cong (n / 2)^{1/2} \quad (1.2)$$


Bu çalışmada küme sayısının belirlenmesi amacı ile (1) numaralı denklemden yararlanılarak küme sayısı 4 olarak belirlenmiştir. Geriye kalan dört adımın sırası ile uygulanabilmesi için nihai veri seti arff dosya tipine dönüştürülmüştür. Çünkü analizlerin gerçekleştirilebilmesi için seçilen WEKA yazılımı arff dosya tipi ile çalışmaktadır. Nitekim nihai veri seti ücretsiz bir veri madenciliği yazılımı olan WEKA 3.8.6 yazılımına

yüklenmiştir. WEKA 3.8.6 yazılımında ortaya çıkan arayüz ekran görüntüsü Şekil 1.2 'de yer almaktadır:



Şekil 1.2. WEKA Ara Yüzünün Görünümü

Şekil 1.2.'de verilerin WEKA 3.8.6 yazılımına aktırılmasının ardından programın arayüzünde değişken isimlerinin ve bu değişkenlere ait minimum, maksimum, ortalama değer ile standart sapma ilgileri yer aldığı görülmektedir. Şekil 1.3.'de ise k-ortalamlar kümeleme algoritması için yüzdelik küme dağılımları görülmektedir:



Şekil 1.3. K-ortalamlar Kümeleme Algoritması İçin Yüzdelik Küme Dağılımları

Weka 3.8.6 yazılımı kullanılarak 2013-2022 dönemlerine ait her yıl için ayrı ayrı kümeleme analizi yapılmış ve 29 OECD üyesi ülkenin on yıllık süreçte yer aldıkları kümeler Tablo 1.4.'de gösterilmiştir. Analizde kullanılan makroekonomik değişkenlere ilişkin son küme merkezleri ise Tablo 1.5. ile Tablo 1.6.'de gösterilmiştir ve bu son küme merkezlerine göre kümelerin temel özellikleri yorumlanmıştır.

Tablo 1.4. Kümeleme Analizi Sonuçları

Yıllar	Küme 0	Küme 1	Küme 2	Küme 3
2013	Yunanistan, İspanya	Almanya, ABD	Avusturya, Çek Cumhuriyeti, Estonya, Finlandiya, Macaristan, İrlanda, Letonya, Litvanya, Lüksemburg, Yeni Zelanda, Norveç, Polonya, Slovenya, İsveç, İsviçre	Avusturalya, Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore, Türkiye, Birleşik Krallık
2014	Yunanistan, İspanya	Almanya, ABD	Avusturya, Çek Cumhuriyeti, Estonya, Finlandiya, Macaristan, İrlanda, Letonya, Litvanya, Lüksemburg, Yeni Zelanda, Norveç, Polonya, Slovenya, İsveç, İsviçre	Avusturalya, Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore, Türkiye, Birleşik Krallık
2015	Yunanistan, İspanya	Almanya, ABD	Avusturalya, Avusturya, Çek Cumhuriyeti, Estonya, Finlandiya, Macaristan, İrlanda, Letonya, Litvanya, Lüksemburg, Yeni Zelanda, Norveç, Polonya, Slovenya, İsveç, İsviçre, Türkiye	Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore, Birleşik Krallık
2016	Yunanistan, İspanya	Almanya, ABD	Avusturalya, Avusturya, Çek Cumhuriyeti, Estonya, Finlandiya, Macaristan, İrlanda, Letonya, Litvanya, Lüksemburg, Yeni Zelanda, Polonya, Slovenya, İsveç, İsviçre	Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Norveç, Kore, Türkiye, Birleşik Krallık
2017	Yunanistan, İspanya, İtalya	Almanya, ABD	Estonya, Letonya, Litvanya, Meksika, Türkiye	Avusturalya, Avusturya, Belçika, Fransa, Japonya, Kanada, Norveç, İsveç, İsviçre, Çek Cumhuriyeti, Finlandiya, Lüksemburg, Polonya, Macaristan, İrlanda, Slovenya, Kore, Yeni Zelanda, Birleşik Krallık
2018	Yunanistan, İspanya, İtalya	Almanya, ABD	Türkiye	Avusturalya, Avusturya, Belçika, Fransa, Japonya, Kanada, Litvanya, Norveç, İsveç, İsviçre, Çek Cumhuriyeti, Estonya,

				Finlandiya, Lüksemburg, Polonya, Macaristan, İrlanda, Meksika, Slovenya, Kore, Letonya, Yeni Zelanda, Birleşik Krallık
2019	Yunanistan, İspanya, Türkiye	Almanya, ABD	Avusturalya, Avusturya, Çek Cumhuriyeti, Estonya, Finlandiya, Macaristan, İrlanda, Letonya, Litvanya, Lüksemburg, Yeni Zelanda, Norveç, Polonya, Slovenya, İsveç, İsviçre	Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore, Birleşik Krallık
2020	Yunanistan, İspanya	Almanya, ABD	Avusturalya, Avusturya, Çek Cumhuriyeti, Estonya, Finlandiya, Macaristan, İrlanda, Letonya, Litvanya, Lüksemburg, Yeni Zelanda, Norveç, Slovenya, İsveç, İsviçre	Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore, Türkiye, Polonya, Birleşik Krallık
2021	Yunanistan, İspanya, Türkiye	Almanya, ABD	Avusturalya, Avusturya, Çek Cumhuriyeti, Estonya, Finlandiya, Macaristan, İrlanda, Letonya, Litvanya, Lüksemburg, Yeni Zelanda, Norveç, Polonya, Slovenya, İsveç, İsviçre	Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore, Birleşik Krallık
2022	Yunanistan, İspanya, Türkiye	Almanya, ABD	Avusturya, Çek Cumhuriyeti, Estonya, Finlandiya, Macaristan, İrlanda, Letonya, Litvanya, Lüksemburg, Yeni Zelanda, Norveç, Slovenya, İsveç, İsviçre	Avusturalya, Belçika, Fransa, Japonya, Kanada, İtalya, Polonya, Meksika, Kore, Birleşik Krallık

29 adet OECD üyesi ülke, 2013 yılında hangi kümelerde yer aldılar ise 2014 yılında da aynı kümelerde yer almışlardır. Buna göre her iki yılda da 29 adet ülkenin %7'si küme 0'da %7'si küme 1'de, %52'si küme 2'de ve %34'ü de küme 3'te yer almıştır. Küme 1'de GSYH, ihracat ve ithalat değerleri en yüksek ve işsizlik oranı en düşük ülkelerin bulunduğu saptanmıştır. Küme 3'te yer alan ülkelerin en yüksek enflasyon oranına, küme 0'da yer alan ülkelerin ise en düşük enflasyon oranına sahip oldukları görülmüştür. İşsizlik oranı en yüksek ülkelerin küme 0'da olduğu belirlenmiştir. O halde küme 1'de bulunan Almanya ve ABD en gelişmiş ülkelerdir. Türkiye'nin de içerisinde bulunduğu küme 3, gelişmiş ülkelerin bulunduğu küme olarak nitelendirilebilir. Fakat küme 3 her ne kadar gelişmiş ülkeleri barındırsa da bu küme en yüksek enflasyon oranına sahip olan kümedir. Yunanistan ve İspanya'nın bulunduğu küme 0, gelişmekte olan ülkeleri içermekle birlikte bu kümedeki ülkelerde işsizlik oranı diğer kümelere göre yüksektir. Geriye kalan 15 ülkenin bulunduğu küme 2 ise daha az gelişmiş ülkeleri temsil etmektedir.

2015 yılı için yapılan kümeleme analizi sonucunda 29 adet ülkenin %7'si küme 0'da %7'si küme 1'de, %59'u küme 2'de ve %28'i ise küme 3'te yer almıştır. 2013 ve 2014 yıllarına göre küme 1'de yer alan ülkelerde herhangi bir değişiklik olmadığı Tablo 1.4.'de görülmektedir. 2013 ve 2014 yıllarında küme 3'te yer alan Avustralya ve Türkiye ise 2015 yılında küme 2'de yer almıştır. Bu yılda da 2013 ve 2014 yıllarında olduğu gibi GSYH, ihracat ve ithalat değerleri en yüksek ve işsizlik oranı en düşük ülkelerin küme 1'de yer aldığı tespit edilmiştir. Enflasyon oranı en yüksek ülkeler küme 3'te yer alırken, enflasyon oranı en düşük ülkeler küme 0'da yer almıştır. İşsizlik oranı en yüksek ülkelerin küme 0'da bulunduğu saptanmıştır. O halde küme 1'de bulunan Almanya ve ABD en gelişmiş ülkelerdir. Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore, Birleşik Krallık'tan oluşan küme 3 ise gelişmiş ülkeleri barındırmaktadır. Fakat küme 3 her ne kadar gelişmiş ülkeleri barındırsa da bu küme en yüksek enflasyon oranına sahip olan kümedir. Yunanistan ve İspanya'nın bulunduğu küme 0, gelişmekte olan ülkeleri içermekle birlikte bu kümedeki ülkelere işsizlik oranı diğer kümelere göre yüksektir. Avustralya ve Türkiye'nin bulunduğu küme 2 ise daha az gelişmiş ülkeleri barındırmaktadır. Buna göre Avustralya ve Türkiye'nin bir önceki yıla göre ekonomik büyüklüğü daha düşük ülkeler ile bir küme oluşturduğunu söylemek mümkündür.

2016 yılı için yapılan kümeleme analizi sonucunda 29 adet ülkenin %7'sinin küme 0'da %7'sinin küme 1'de, %52'sinin küme 2'de ve %34'ünün de küme 3'te yer aldığı tespit edilmiştir. Tablo 1.4.'de görüldüğü üzere, bir önceki yıla göre küme 0 ve küme 1'de yer alan ülkelere bir değişiklik olmamıştır. Ancak 2015 yılında küme 2'de yer alan Norveç ve Türkiye'nin 2016 yılında küme 3'e geçtiği belirlenmiştir. Bu yılda da önceki yıllarda olduğu gibi küme 1; GSYH, ihracat ve ithalat değerleri en yüksek, işsizlik oranı en düşük ülkeleri barındırmış ve Almanya ile ABD'nin en gelişmiş ülkeler oldukları görülmüştür. Norveç ve Türkiye'nin de içerisinde yer aldığı küme 3, gelişmiş ülkeleri barındırmakla birlikte en yüksek enflasyon oranına sahip küme olarak tespit edilmiştir. Bu doğrultuda Norveç ve Türkiye'nin bir önceki yıla göre ekonomik büyüklüğü daha fazla olan ülkeler ile bir küme oluşturduğunu söylenebilir. Yunanistan ile İspanya, gelişmekte olan ülkelerin yer aldığı küme 0'da yer almıştır. Ancak bu küme işsizlik oranının en yüksek olduğu kümedir. Küme 2 ise daha az gelişmiş ülkeleri temsil etmektedir.

2017 yılı için yapılan kümeleme analizi sonucunda 29 adet ülkenin %10'u küme 0'da, %7'si küme 1'de, %17'si küme 2'de ve % 66'sı küme 3'te yer almıştır. Ülkelerin

önceki yıllara göre yer aldıkları kümelerde ciddi değişiklikler yaşandığı tespit edilmiştir. Nitekim öncelikle daha önceki yıllarda küme 3'te yer alan İtalya'nın küme 0'a, Meksika ve Türkiye'nin de küme 3'ten küme 2'ye geçtiği saptanmıştır. Ayrıca Avusturalya, Avusturya, İsveç, İsviçre, Çek Cumhuriyeti, Finlandiya, Lüksemburg, Polonya, Macaristan, İrlanda, Slovenya ve Yeni Zelanda'nın küme 2'den küme 3'e geçtiği tespit edilmiştir. Küme 1'de ise herhangi bir değişiklik görülmemiştir. Önceki yıllarda olduğu gibi küme 1; GSYH, ihracat ve ithalat değerleri en yüksek, işsizlik oranı en düşük ülkeleri barındırmış ve Almanya ile ABD'nin en gelişmiş ülkeler oldukları görülmüştür. Yunanistan, İspanya ve İtalya'nın yer aldığı küme 0 ise gelişmiş ülkeleri barındırmakla birlikte işsizlik oranının en yüksek olduğu kümedir. Bu kapsamda Yunanistan, İspanya ve İtalya'nın bir önceki yıla göre ekonomik büyüklüğünde bir artış olmakla birlikte ekonomilerinde ciddi bir işsizliğin söz konusu olduğu söylenebilir. Küme 3, gelişmekte olan ülkeleri temsil ederken; Meksika ve Türkiye'nin de içerisinde bulunduğu küme 2 ise, enflasyon oranının en yüksek olduğu küme olup daha az gelişmiş ülkeleri temsil etmektedir.

2018 yılında 29 adet ülkenin %10'u küme 0'da, %7'si küme 1'de, %3'ü küme 2'de ve % 79'u küme 3'te yer almıştır. Bir önceki yıla göre küme 0 ve küme 1'de yer alan ülkelerde herhangi bir değişiklik yaşanmamıştır. Ancak bir önceki yıl küme 2'de yer alan Estonya, Letonya, Litvanya ve Meksika'nın küme 2'den küme 3'e geçtiği ve Türkiye'nin tek başına küme 2'yi oluşturduğu Tablo 1.4.'de görülmektedir. Tablo 1.5. incelendiğinde önceki yıllarda olduğu gibi küme 1; GSYH, ihracat ve ithalat değerleri en yüksek, işsizlik oranı en düşük ülkeleri barındırmış ve Almanya ile ABD'nin en gelişmiş ülkeler oldukları görülmüştür. Türkiye, gelişmiş ülkeleri temsil eden küme 2'de yer almıştır. Her ne kadar Türkiye, bir önceki yıla göre ekonomik büyüklüğünü arttırmış olsa da geçen yıl olduğu gibi bu yıl da en yüksek enflasyonun bulunduğu kümede yer almıştır. Yunanistan, İspanya ve İtalya'nın yer aldığı küme 0, işsizlik oranının en yüksek olduğu kümedir ve gelişmekte olan ülkeleri temsil etmektedir. Küme 3 ise daha az gelişmiş ülkeleri temsil etmektedir.

2019 yılında 29 adet ülkenin %10'u küme 0'da, %7'si küme 1'de, %55'i küme 2'de ve % 28'i küme 3'te yer almıştır. Bir önceki yıla göre küme 1'de yer alan ülkelerde herhangi bir değişiklik yaşanmadığı belirlenmiştir. Fakat 2018 yılında küme 0'da yer alan İtalya küme 3'e, tek başına küme 2'de yer alan Türkiye ise küme 0'a geçmiştir. Aynı zamanda 2018 yılında küme 3'te yer alan Belçika, Fransa, Japonya, Kanada, Meksika, Kore ve Birleşik Krallık yine küme 3'te yer almış, bu ülkelerin dışında kalan diğer ülkeler

ise küme 2'yi oluşturmuştur. Önceki yıllarda olduğu gibi küme 1; GSYH, ihracat ve ithalat değerleri en yüksek, işsizlik oranı en düşük ülkeleri barındırmış ve Almanya ile ABD'nin en gelişmiş ülkeler oldukları görülmüştür. Küme 3, gelişmiş ülkeleri temsil eder iken; İtalya'nın bir önceki yıla göre ekonomik büyüklüğünde artış yaşandığı belirlenmiştir. Yunanistan, İspanya ve Türkiye'den oluşan küme 0 ise gelişmekte olan ülkeleri temsil etmektedir. Aynı zamanda küme 0, enflasyon ve işsizlik oranının en yüksek olduğu küme olarak belirlenmiştir. Bu kapsamda Türkiye'nin bir önceki yıla göre ekonomik büyüklüğü daha düşük olan ülkeler ile bir küme oluşturduğu ve enflasyon probleminin yanında işsizlik sorununu daha fazla yaşamaya başladığını söylemek mümkündür. Küme 2'nin ise diğer kümelere göre nispeten daha az gelişmiş ülkeleri temsil ettiği belirlenmiştir.

2020 yılında 29 adet ülkenin %7'si küme 0'da, %7'si küme 1'de, %52'si küme 2'de ve % 34'ü küme 3'te yer almıştır. Bir önceki yıla göre küme 1'de yer alan ülkelerde herhangi bir değişiklik yaşanmadığı ancak bir önceki yıl küme 0'da yer alan Türkiye'nin ve küme 2'de bulunan Polonya'nın küme 3'e geçtiği saptanmıştır. Tablo 1.5. ve Tablo 1.6. incelendiğinde açıkça görülmüştür ki bu yılda da küme 1; GSYH, ihracat ve ithalat değerleri en yüksek, işsizlik oranı en düşük ülkeleri barındırmıştır. O halde Almanya ile ABD en gelişmiş ülkelerdir. Gelişmiş ülkeleri temsil eden küme 3, enflasyon oranının en fazla olduğu küme olarak bulunmuştur. Bu doğrultuda Türkiye ve Polonya'nın bir önceki yıla göre ekonomik büyüklüğü daha fazla olan ülkeler ile bir küme oluşturduğu ancak ekonomilerinde ciddi bir enflasyon sorunu ile karşı karşıya kaldıkları söylenebilir. Gelişmekte olan ülkeleri temsil eden ve işsizlik oranının en fazla olduğu küme olarak nitelendirilen küme 0'da yalnızca iki adet Akdeniz ülkesi (Yunanistan ve İspanya) yer almıştır. Nispeten daha az gelişmiş ülkeleri ise küme 2 temsil etmiştir.

2021 yılında 29 adet ülkenin %10'ü küme 0'da, %7'si küme 1'de, %55'i küme 2'de ve % 28'i küme 3'te yer almıştır. Bir önceki yıla göre küme 0'da bulunan ülkelerde bir değişiklik olmamıştır. Ancak bir önceki yıl küme 3'te yer alan Türkiye'nin küme 0'a Polonya'nın ise küme 2'ye geçtiği Tablo 1.4.'de görülmektedir. Son küme merkezleri incelendiğinde; küme 1; GSYH, ihracat ve ithalat değerleri en yüksek, işsizlik oranı en düşük ülkeleri barındırmış ve Almanya ile ABD'nin en gelişmiş ülkeler oldukları görülmüştür. 8 adet ülkenin yer aldığı küme 3, gelişmiş ülkeleri temsil ederken; Türkiye'nin de içerisinde yer aldığı küme 0 gelişmekte olan ülkeleri temsil etmiştir. Aynı zamanda küme 0, enflasyon ve işsizlik oranının en yüksek olduğu kümedir. Nispeten daha

az gelişmiş ülkeler ise küme 2'yi oluşturmuştur. Bu kapsamda bir önceki yıla göre kümeleri değişen Türkiye ve Polonya'nın ekonomik olarak gerilediğini söylemek mümkündür.

Son olarak 2022 yılı için yapılan kümeleme analizi sonucunda 29 adet ülkenin %10'u küme 0'da, %7'si küme 1'de, %48'i küme 2'de ve % 34'ü küme 3'te yer almıştır. Bir önceki yıla göre küme 0 ve küme 1'de yer alan ülkelerde herhangi bir değişiklik yaşanmaz iken, Avustralya ve Polonya'nın küme 2'den küme 3'e geçtiği Tablo 1.4.'de görülmektedir. Almanya ve ABD'nin yer aldığı küme 1, önceki yıllarda olduğu gibi en gelişmiş ve işsizlik oranı en düşük küme olarak belirlenmiştir. Küme 3 gelişmiş ülkeleri temsil ederken; Yunanistan, İspanya ve Türkiye'den oluşan küme 0, gelişmekte ülkeleri temsil etmektedir. Aynı zamanda küme 0, enflasyon ve işsizlik oranının en yüksek olduğu kümedir. Küme 2 ise nispeten daha az gelişmiş ülkeleri temsil etmiştir. Bu kapsamda bir önceki yıl küme 2'de yer alan ve 2022 yılında küme 3'e geçen Avustralya ve Polonya'nın ekonomik olarak daha az gelişmiş ülkeler ile bir küme oluşturduğu söylenebilir.

Tablo 1.5. GSYH, İhracat ve İthalat Değişkenlerinin Son Küme Merkezleri

Yıllar	GSYH				İhracat				İthalat			
	Küme 0	Küme 1	Küme 2	Küme 3	Küme 0	Küme 1	Küme 2	Küme 3	Küme 0	Küme 1	Küme 2	Küme 3
2013	0.1411	0.5855	0.1112	0.1983	0.1832	0.865	0.1451	0.3259	0.1649	0.7071	0.1268	0.2693
2014	0.1405	0.5861	0.1111	0.1971	0.1824	0.8674	0.1452	0.3219	0.1657	0.7035	0.1268	0.2632
2015	0.1404	0.5848	0.118	0.2041	0.1767	0.8497	0.1478	0.3433	0.1589	0.685	0.13	0.2675
2016	0.1418	0.5884	0.1141	0.1944	0.1818	0.8633	0.1484	0.3097	0.1606	0.6908	0.1287	0.2422
2017	0.1622	0.5894	0.1387	0.1452	0.2434	0.8717	0.1587	0.2246	0.1933	0.6973	0.1442	0.1815
2018	0.1609	0.5884	0.188	0.1412	0.244	0.8734	0.1781	0.2128	0.1956	0.7012	0.1672	0.1741
2019	0.1566	0.5885	0.1143	0.2016	0.1829	0.8613	0.1525	0.3472	0.1636	0.6966	0.1299	0.2685
2020	0.1381	0.5884	0.1124	0.1928	0.1892	0.8838	0.1532	0.329	0.1599	0.6987	0.1268	0.2432
2021	0.1535	0.5831	0.1145	0.1952	0.1922	0.8674	0.1606	0.3549	0.1659	0.6977	0.1305	0.264
2022	0.1535	0.5831	0.1145	0.1952	0.1922	0.8674	0.1606	0.3549	0.1659	0.6977	0.1305	0.264

Tablo 1.6. Enflasyon ve İşsizlik Oranı Değişkenlerinin Son Küme Merkezleri

Yıllar	Enflasyon				İşsizlik Oranı			
	Küme 0	Küme 1	Küme 2	Küme 3	Küme 0	Küme 1	Küme 2	Küme 3
2013	0.2108	0.3288	0.3039	0.3957	0.8759	0.2042	0.272	0.2379
2014	0.1457	0.3028	0.2423	0.3908	0.8629	0.1722	0.2465	0.2321
2015	0.1525	0.2745	0.2922	0.3156	0.8456	0.1565	0.2438	0.2254
2016	0.129	0.2583	0.2119	0.3583	0.8225	0.1509	0.2376	0.2423
2017	0.181	0.2095	0.4784	0.1952	0.6927	0.1503	0.2894	0.214
2018	0.1332	0.1807	0.9	0.1789	0.7023	0.166	0.5147	0.2345
2019	0.3746	0.1738	0.1881	0.1621	0.7836	0.1728	0.2436	0.2774
2020	0.1274	0.2253	0.2258	0.3062	0.876	0.2984	0.298	0.3271
2021	0.4302	0.2665	0.2381	0.2083	0.8405	0.21	0.2822	0.2975
2022	0.4302	0.2665	0.2381	0.2083	0.8405	0.21	0.2822	0.2975

1.4. Tartışma

29 OECD üyesi ülkenin 5 adet makroekonomik değişken yardımı ile 2013-2022 tarihlerini kapsayan on yıllık süreç içerisinde ekonomik gelişmişliklerine göre kümeler ayrılmasını ve yıllar içerisinde kümelerde nasıl değişikliklerin olduğunu belirlemeyi amaçlayan bu çalışmanın sonucunda ülkeler dört kümeye ayrılmıştır. Ülkelerin ekonomik göstergelerine göre yıllar içerisinde farklı kümelerde yer alabildikleri ulaşılan ilk bulgudur. Nitekim Avustralya, Norveç, Türkiye, İtalya, Estonya, Letonya, Litvanya, Meksika ve Polonya yıllar içerisinde kümeleri değişen ülkelerdir. Bunlara ek olarak ise bazı ülkelerin her yıl birlikte küme oluşturdıkları elde edilen bir diğer önemli bulgudur. Öyle ki bu çalışmada dünya ekonomisinde önemli rol oynayan Amerika ile Almanya tam da beklendiği gibi her yıl aynı kümede yer almışlardır. Teknoloji lideri Amerika ile mühendislik alanındaki başarısı ile bilinen Almanya'nın her yıl aynı kümede yer almasının nedeni olarak her iki ülkedeki çok çeşitli ekonomik yapı sayesinde uluslararası ticaretteki etkin konumları, düşük işsizlik oranları ve etkili merkez bankası politikaları ile istikrarlı bir enflasyonun varlığı gösterilebilir. Nitekim 2013-2022 yılları arasında OECD ülkeleri arasında en çok ihracat rakamına sahip ülkeler Almanya ve Amerika'dır. Buna ek olarak aynı dönemde OECD ülkeleri arasında Amerika en çok ithalat rakamına sahip ülke iken; Almanya ikinci sırada gelmektedir. Amerika'nın Covid-19 krizinin yaşandığı 2020 yılındaki işsizlik rakamı haricinde 2013-2022 döneminde her iki ülkenin de işsizlik rakamları OECD ülkelerinin ortalamasının altındadır. Yine aynı dönemde enflasyonun her iki ülkede de dalgalı bir seyir izlemediği söylenebilir (<https://stats.oecd.org/> Erişim tarihi: 13.06.2025). Almanya ve Amerika'nın dışında çalışmada Yunanistan ile İspanya'nın da her yıl aynı kümede yer aldıkları saptanmıştır. Nitekim her iki ülkede ortak problemlere rastlanmaktadır. Öyle ki her iki ülkede de 2008 Küresel Krizi sonrasında genç işsizlik hızla artarak ekonomik ve sosyal bir sorun haline gelmiştir (Bell & Blanchflower, 2015: 1). Ayrıca Euro bölgesinde bulunan her iki ülkede Euro bölgesinin etkisi ile benzer ekonomik politikaların uygulanıyor olması ve turizm sektörünün üstlendiği kritik rolün ülkelerin birlikte kümelenmesine yol açtığı düşünülmektedir. Bu sonuçlar üç farklı uzaklık matrisi kullanarak yaptığı kümeleme analizinde her defasında Amerika ile Almanya'nın ve Yunanistan ile İspanya'nın hep aynı kümede yer aldığını saptayan Billková (2019) ile benzerdir. Ayrıca çalışmasında 2008-2015 yılları arasında İrlanda, Letonya, Litvanya, Polonya, Çek Cumhuriyeti ve Estonya'nın aynı grupta yer aldığını belirleyen Marčeta & Boinec (2022) ile benzer bulgulara bu çalışmada da

ulaşılmıştır. Avrupa Birliği entegrasyonu ve bu kapsamda uygulanan politikalar düşünüldüğünde bahsedilen ülkelerin ekonomileri arasında görülen paralelliklerin şaşırtıcı olmadığı düşünülmektedir.

Çalışmada yıllar içerisinde kümelerinde değişiklik olan ve her yıl birlikte küme oluşturan ülkelerin belirlenmesinin dışında son küme merkezleri dikkate alınarak ülkelerin ekonomik gelişmişlikleri de tespit edilerek önemli bulgular elde edilmiştir. Elde edilen bulgular beklenildiği gibi literatürde yer alan çalışma sonuçları ile uyumludur. Nitekim Megyesiova & Lieskovska (2018)'e benzer şekilde bu çalışmada da Amerika ve Almanya'nın en yüksek GSYH değerine sahip ülkeler olarak en gelişmiş ülkeleri temsil eden kümede yer aldıkları tespit edilmiştir. Nitekim her iki ülkenin GSYH değerleri incelendiğinde OECD ülkeleri arasında Amerika'nın ilk sırada yer aldığı görülmektedir (<https://stats.oecd.org/> Erişim tarihi: 13.06.2025). Çalışmada literatür ile uyumlu şekilde elde edilen önemli sonuçlardan bir tanesi de Belçika, Fransa, Japonya, Kanada, Kore ve Birleşik Krallık'ın gelişmiş ülkeleri temsil ediyor olmasıdır. Öyle ki Marçeta & Boinec (2022) çalışmalarında 2015-2019 döneminde Belçika, Fransa ve Birleşik Krallık'ın GSYH açısından Avrupa Birliği ülkeleri içerisinde en iyi konumdaki kümede yer aldıklarını belirlemişlerdir. Bu çalışmada da Belçika, Fransa ve Birleşik Krallık Amerika ve Almanya'dan sonra OECD ülkeleri içerisindeki en gelişmiş ülkelerdir. Eğer Avrupa Birliği ülkeleri açısından değerlendirecek olur ise bu ülkelerin Marçeta & Boinec (2022)'nin çalışma sonuçlarına benzer şekilde makroekonomik açıdan en iyi konumdaki ülkeler olduklarını söylemek mümkün olacaktır. Yine bu çalışmada tüketici fiyatları dikkate alındığında Demirkale & Özarı (2020)'nin elde ettiği sonuçlara benzer olarak Türkiye'nin yıllar içerisinde her zaman enflasyon problemi yaşadığı saptanmıştır. Nitekim Türkiye'nin 2013-2022 döneminde enflasyon oranına ait veriler incelendiğinde OECD ortalamasının oldukça üstünde olduğu görülmektedir (<https://stats.oecd.org/> Erişim tarihi: 13.06.2025). Ayrıca özellikle son yıllarda Rusya-Ukrayna savaşının sebep olduğu enerji maliyetlerindeki artış Türkiye'de enflasyonu daha da tetiklemiştir. Son olarak ise; Timor & Yüzbaşı Künc (2021)'in elde ettiği sonuçlara benzer olarak bu çalışmada da 2019 yılında Yunanistan, İspanya ve Türkiye gelişmekte olan ülkeler olarak nitelendirilmişlerdir. 2008 Küresel Krizi sonrasında ekonomik sıkıntılar geçiren Yunanistan'da Mayıs 2013'de %63.70 (<https://tr.tradingeconomics.com/greece/youth-unemployment-rate> Erişim tarihi: 14.06.2025) ile İspanya'da ise Temmuz 2013'de %56.20 ile en yüksek seviyeye çıkan genç işsizlik oranına

<https://tr.tradingeconomics.com/spain/youth-unemployment-rate> Erişim tarihi: 14.06.2025) ek olarak 2018 yılında yaşanan döviz kuru dalgalanmalarının ardından ekonomik sıkıntıların atlatmaya çalışan Türkiye'nin 2019 yılında gelişmekte olan ülke olarak tespit edilmesi beklenen bir sonuç olarak karşımıza çıkmaktadır.

Yapılan kümeleme analizi sonucunda literatürdeki çalışmalar ile uyumlu bulguların yanında farklı bulgulara da rastlanmıştır. Yüzbaşı Künc (2018) 2017 yılında İspanya ve İtalya'nın bir önceki yıla göre ekonomik olarak gerilediğini tespit ederken bu çalışmada tam aksine ilgili ülkelerin bir önceki yıla göre ekonomik büyüklüklerinin arttığı sonucuna ulaşılmıştır. Her iki ülkenin 2016 ve 2017 yıllarına ait GSYH değerleri incelendiğinde ise bu çalışmada tespit edildiği gibi ekonomik büyüklüklerinde artış yaşandığı tespit edilmiştir (<https://stats.oecd.org/> Erişim tarihi: 13.06.2025). Diğer taraftan bu çalışmada 2019 yılında İtalya'nın gelişmiş ülkeleri temsil eden kümede yer aldığı saptanırken; Timor & Yüzbaşı Künc (2021) çalışmalarında ilgili yılda İtalya'nın gelişmekte olan ülkeleri temsil eden kümede yer aldığını belirlemişlerdir. Fakat 2019 yılında bir önceki yıla göre İtalya'nın GSYH değerinde artış yaşanmıştır. Dahası aynı yılda İtalya Avrupa'nın en büyük üçüncü, küresel olarak ise yedinci en büyük ihracatçısı konumundadır (<https://www.weforum.org> Erişim tarihi: 05.03.2025). Dolayısı ile İtalya'nın o dönemki ekonomik görünümü Timor & Yüzbaşı Künc (2021)'ün elde ettiği bulguların aksine bu çalışmada elde edilen bulguları destekleyecek niteliktedir. Yine benzer şekilde bu çalışmada Belçika, Kanada ve Birleşik Krallık'ın gelişmiş ülkeleri temsil eden kümede yer aldıkları belirlenir iken; bu çalışmanın aksine Billková (2019) ise çalışmasında Belçika, İngiltere ve Kanada'nın en gelişmiş ülkeleri temsil eden kümede Amerika ve Almanya ile birlikte yer aldığını saptamıştır. Fakat Amerika ve Almanya'nın aksine Belçika ve Kanada'da yüksek genç işsizlik oranları mevcuttur. Öyle ki Belçika'da genç işsizlik oranı 2014 yılının ocak ayında %26,20 ile en yüksek seviyeye ulaşmıştır. Benzer şekilde Kanada'da da genç işsizlik oranı Covid-19 krizinin şiddetli ekonomik etkilerinin yaşandığı 2020 yılının mayıs ayında tüm zamanların en yüksek seviyesine ulaşmıştır (<https://tr.tradingeconomics.com/belgium/youth-unemployment-rate> Erişim Tarihi: 13.06.2025). Birleşik Krallık'ın GSYH ve ihracat değerleri ise Almanya ve Amerika'ya kıyasla oldukça düşük seviyelerdedir (<https://stats.oecd.org/> Erişim tarihi: 13.06.2025). Dolayısı ile Billková (2019)'un elde ettiği sonuçların aksine Belçika, Kanada ve Birleşik Krallık'ın Almanya ve Amerika ile aynı kümede yer alması beklenemez.

1.5. Çıkarımlar

1.5.1. Teorik ve uygulama çıkarımları

Bu çalışma hiyerarşik olmayan veri madenciliği yöntemlerinden k-ortalamlar kümeleme algoritmasının veri madenciliğine özel bir program olan WEKA yazılımında uygulanmasına dayanmaktadır. Bu kapsamda metodolojik katkılar açısından bu çalışma öncelikle veri madenciliğine özel yazılımların istatistiksel gücünü ortaya koymaktadır. Nitekim bu çalışma ekonomi alanında oluşan büyük veri yığınlarından elde edilecek yararlı bilgilerin veri madenciliğine özel yazılımlar kullanılarak elde edilebilirliğini göstermektedir. Diğer yandan k-ortalamlar kümeleme algoritması araştırmacının küme sayısının ne olacağı hakkında bir fikri bulunmuyor ise çeşitli formüller yardımı ile de küme sayısının hesaplanabilmesine olanak sağlamaktadır. Bu kapsamda ikinci olarak, bu çalışma hiyerarşik olmayan k-ortalamlar kümeleme algoritmasının uygulama kolaylığını araştırmacılara göstermektedir. Üçüncüsü, önceki çalışmaların çoğu ülkelerin sınıflandırılmasında tek bir yılı baz alır iken; on yıllık bir zaman dilimi için ayrı ayrı kümeleme analizinin gerçekleştirildiği bu çalışma mevcut literatürdeki eksiklik nedeni ile önemli hale gelmektedir. Son olarak ise, bu çalışma diğer çalışmaların aksine OECD ülkelerinin GSYH, ihracat, ithalat, enflasyon ve işsizlik oranı değişkenleri kullanılarak ekonomik gelişmişliklerine göre kümeler ayrılabilirliğini göstererek mevcut literatüre katkıda bulunmaktadır.

OECD ülkelerinin politika belirleyicileri bu çalışmadan büyük ölçüde yararlanacaklardır. Nitekim bu çalışma yıllar içerisinde OECD ülkelerinin gelişme düzeyleri arasında oluşan farklılıkları ortaya koymuştur. Öncelikle politika belirleyiciler yıllar içerisinde ülkelerin gelişme düzeyleri arasında oluşan farklılıkların nedenlerini bu çalışmada seçilen makroekonomik değişkenler yardımı ile tespit edebilirler. Ardından ekonomik gelişme düzeyini arttırmak isteyen ülkeler için politika belirleyebilme imkanına sahiptirler. Öyle ki ihracatta ve GSYH rakamlarında yaşanacak artışın yanı sıra enflasyon ve işsizlik rakamlarında meydana gelecek azalışlar OECD üyesi ülkelerinin ekonomik gelişme düzeyleri arasında ciddi farklılıklara sebebiyet vermektedir. Bu kapsamda ülke dinamiklerine göre uygulanacak politikalar ile ülkeler ekonomik gelişme düzeylerini arttırabilirler. Sonuç olarak, bu çalışma ekonomik gelişme düzeyini arttırmak isteyen OECD üyesi ülkelerin politika belirleyicileri için önemli uygulama çıkarımlarına sahiptir.

1.6. Sonuç ve Öneriler

Günümüzde dijitalleşme sürecinin sebep olduğu dönüşüm ile birlikte veri tabanlarında çok büyük miktarda veri birikmektedir. Bu doğrultuda, biriken büyük veri yığınları içerisinde yararlı bilgilerin açığa çıkarılabilmesi de adeta bir zorunluluk haline gelmiştir. Bu zorunluluk ise büyük miktarda veriden yararlı bilgilerin elde edilebilmesi için veri madenciliği sürecine duyulan ihtiyacı arttırmıştır.

Bu çalışmada hiyerarşik olmayan veri madenciliği yöntemlerinden k-ortalamlar algoritması kullanılarak 29 OECD üyesi ülkeye ait 5 adet makroekonomik değişken ile 2013-2022 dönemleri için yıllık veriler ayrı ayrı kümeleme analizi gerçekleştirilmiştir. Yapılan analizler sonucunda 5 adet makroekonomik değişkenin son küme merkezlerine göre kümeler arasındaki farklılıklar ortaya konulmuştur. Her yıl için ayrı ayrı yapılan kümeleme analizi sonucunda; teknoloji alanındaki liderliği ile bilinen Amerika ve otomotiv mühendisliği alanındaki etkinliği ile tanınan Almanya'nın her yıl birlikte en gelişmiş ülkeleri temsil eden küme 1'i oluşturduğu saptanmıştır. Çünkü çok çeşitli ekonomik yapıları sayesinde uluslararası ticarete güçlü konumda olan, etkin yönetim stratejileri sayesinde fiyat istikrarını ve düşük işsizlik oranlarını sağlamış olan iki ülkenin oluşturduğu küme 1; her zaman en yüksek GSYH, ihracat, ithalat değerlerine ve en düşük işsizlik oranına sahip olmuştur. Küme 3 ise; 2017 ve 2018 yılı haricinde her zaman gelişmiş ülkeleri temsil etmiştir. Bu kapsamda yüksek gelir düzeyine sahip, gelişmiş sanayi yapıları, güçlü hizmet sektörünün varlığı ve yüksek teknolojiye dayalı ekonomileri ile ön plana çıkan Belçika, Fransa, Japonya, Kanada, Kore ve Birleşik Krallık her yıl küme 3'te yer almıştır. Bu ülkeler kalıcı ekonomik büyümeyi sürdürebilmek için ülke dinamiklerine göre politikalar oluşturmalıdır. Öyle ki Belçika ve Kanada'nın genç işsizliği azaltacak, Japonya ise yaşlı işgücüne istihdam sağlayacak alanlara yönelebilir. Akdeniz ülkelerinden Yunanistan ve İspanya ise her yıl birlikte işsizlik oranının en yüksek olduğu ve gelişmekte olan ülkeleri temsil eden küme 0'da yer almıştır. Nitekim genç nüfusun yoğun her iki ülke de özellikle 2008 Küresel Krizi sonrasında görülen yüksek genç işsizlik oranlarının varlığının bu sonucun ortaya çıkmasına zemin hazırladığı söylenebilir. Bu kapsamda her iki ülkede de genç nüfusun işsizliğini azaltmak adına turizm ve teknoloji gibi büyüme potansiyeli yüksek alanlara yatırım yapılabilir. Dahası bu alanlarda eğitimler ve girişimcilik destekleri verilebilir. Covid-19 salgının yarattığı ekonomik krizin şiddetlendiği 2021 ve Rusya-Ukrayna savaşının başladığı 2022 yıllarında küme 0'a Türkiye'nin de dahil olduğu görülmüştür. Kısacası Covid-19

salgınının ve Rusya-Ukrayna savaşının hemen öncesinde gelişmiş ülke konumunda yer alan Türkiye, salgının yarattığı ekonomik kriz ve savaşın neden olduğu ekonomik zorluklar sonucunda gelişmekte olan ülkelerin yer aldığı kümeye geçiş yapmıştır. Çünkü savaş koşulları Türkiye’de enerji maliyetlerinin yükselmesine ve dolayısı ile enflasyonda artışa sebep olmakla birlikte; Covid- 19 salgını da Türkiye’de turizm, ticaret, yatırım ve finans alanlarında belirsizliğe yol açmıştır. Nitekim Türkiye’nin Yunanistan ve İspanya ile gelişmekte olan ülkeleri temsil eden küme 0’ı oluşturduğu her iki yılda da küme 0, işsizlik oranının yanında enflasyon oranının da en yüksek olduğu küme olarak belirlenmiştir. Bu doğrultuda Türkiye’nin yıllar içerisinde gelişmiş, gelişmekte olan ve az gelişmiş ülkeler ile kümeler oluşturduğu söylenebilir. Türkiye’nin bulunduğu tüm kümelerde ise; her zaman yüksek enflasyon söz konusu olmuştur. Dahası 2018 yılında gelişmiş bir ülke olarak nitelendirilen Türkiye’nin yüksek enflasyon sebebi ile diğer ülkelerden ayrılarak tek başına küme 2’yi oluşturduğu da belirlenmiştir. Bu durum açıkça göstermektedir ki; son yıllarda gelişmekte olan ülkeler arasında yer alan Türkiye’de en önemli yapısal makroekonomik sorunlardan birisi kronikleşen enflasyondur. Türkiye’de enflasyon probleminin çözümü için yapısal reformların yanı sıra istikrarlı merkez bankası politikalarına ve mali disipline ihtiyaç duyulduğu söylenebilir. Türkiye’nin tek başına gelişmiş bir ülke olarak küme 2’de yer aldığı 2018 yılı haricinde küme 2, her yılda az gelişmiş ülkeleri barındırmıştır. Bu kapsamda Baltık ülkelerinden Estonya, Letonya ve Litvanya’nın 2018 yılı haricinde her yıl küme 2’de az gelişmiş ülkeler olarak yer aldıkları söylenebilir. Dinamik ve gün geçtikçe artan ekonomik performansları dikkate alındığında bu ülkelerde kalıcı ve sürdürülebilir büyümeyi sağlayacak politikaların geliştirilmesi gerekmektedir.

Çalışmanın kapsamına giren 2013-2022 dönemi, Covid- 19 salgının neden olduğu ekonomik kriz, Rusya-Ukrayna savaşı ile bu savaşın ortaya çıkardığı enerji krizi ve jeopolitik gerginlikler nedeni ile küresel ekonominin sıkça şoklara maruz kaldığı bir dönem olmuştur. Bu şokların bölgesel kalkınma politikaları üzerindeki etkileri, OECD ülkelerinde birçok risk unsurunun yeniden değerlendirilmesine duyulan ihtiyacı gözler önüne sermiştir. Bu kapsamda 19-20 Mayıs 2025 tarihlerinde Polonya’nın Varşova kentinde OECD Bölgesel Kalkınma Politikası Bakanlar Toplantısı düzenlenmiştir. Bu toplantıda üzerinde durulan konulardan ilki; OECD ülkelerinde ekonomik büyümenin kilit unsurlarından birisi olan üretkenlik artışının önemli ölçüde zayıflamış olmasıdır. Bu nedenle toplantıda özellikle şokları, doğal afetleri ve jeopolitik riskleri de hesaba katan

sürdürülebilir ve uzun vadeli üretkenlik artışına odaklanmanın önemi vurgulanmıştır. Bunun içinde bölgesel bazda yerel politikaların uygulanmasının gerekliliği, altyapı yatırımlarında da çok bölgeli yaklaşımlar benimsenmesi, inovasyon politikalarının farklı alanlarda da yaygınlaştırılması, ara ve ikinci kademedeki şehirlerin gelişimlerinin desteklenmesi yapılabilecekler arasında yer almıştır. Toplantıda üzerinde durulan konulardan ikincisi; şehirlerden kırsal alanlara kadar tüm bölgelerde dijital geçişin fırsatlarından yararlanmak olmuştur. Çünkü dijital altyapı eksikliklerinin önemli bir düzeyde olduğu vurgulanmıştır. Bu kapsamda toplantıda dijital altyapı yatırımlarına önem verilmesi, ulusal dijital stratejiler geliştirilmesi ve kamu hizmetlerinin dijitalleşmesinin gerekliliği vurgulanmıştır. Üçüncü olarak toplantıda, ülkelerin rekabet gücü için akıllı bir yeşil geçişin sağlanmasının gerekliliğine vurgu yapılmıştır. Bu konuda da özellikle bölgesel politikaların önemine değinilmiştir. Toplantıda dördüncü olarak; göç ve nüfus yaşlanmasını içeren demografik değişime dikkat çekilmiştir. Göç alan alanlardaki baskıların hafifletilmesi için uygun fiyatlı konutların yapılması, bölgelerin çekiciliğinin artırılması ve yaşlanan nüfusun hükümetlerin bütçelerinde yaratacağı mali baskının azaltılmasına dair çözüm önerilerine odaklanılmıştır. Son olarak ise toplantıda kamu ve özel sektör yatırımlarının artırılmasının gerekliliğine değinilmiştir. Bunun için ise, yatırım stratejilerinin bölgesel ihtiyaçlara göre belirlenmesi, yatırım fonlarının özellikle yeşil ve dijital dönüşüme uyumlu olması gerektiğinin altı çizilmiştir (<https://www.oecd.org/content/dam/oecd/en/events/2025/05/ministerial-meeting-on-regional-development-policy/kip-rdpc-ministerial-meeting-2025.pdf> Erişim Tarihi: 30.10.2025). Çalışmanın sonucunda elde edilen bulgular neticesinde OECD ülkelerinin bölgesel kalkınma politikaları revize edilebilir. Nitekim sürdürülebilir büyümenin sağlanması adına 2030 Sürdürülebilir Kalkınma Hedefleri içerisinde yer alan on yedi bütünsel hedef (Yoksulluğa son, sıfır açlık, sağlıklı ve kaliteli yaşam, nitelikli eğitim, toplumsal cinsiyet eşitliği, temiz su ve sanitasyon, erişilebilir ve temiz enerji, insana yakışır iş ve ekonomik büyüme, sanayi yenilikçilik ve altyapı, eşitsizliklerin azaltılması, sürdürülebilir şehirler ve topluluklar, sorumlu üretim ve tüketim, iklim eylemi, sudaki yaşam, karasal yaşam, barış adalet ve güçlü kurumlar, amaçlar için ortaklıklar) (<https://www.undp.org/sustainable-development-goals> Erişim tarihi: 02.11.2025) çerçevesinde politikalar oluşturulabilir. Aynı zamanda üretkenlik artışının hızlanması ve dijital dönüşümün fırsatlarından daha iyi yararlanılabilmesi adına özellikle Almanya ve Amerika gibi yüksek ihracat ve ithalat rakamlarına sahip OECD ülkelerinde elektronik ihracatın desteklenmesi ve bu konuda eğitimler verilmesinin yanı sıra gümrük

süreçlerinin dijitalleşmesi için gerekli altyapının desteklenmesine yönelik politikalar oluşturulması yararlı olacaktır. Ayrıca demografik değişimler ve Japonya gibi yaşlı nüfusun çoğunlukta olduğu ülkelerde yaşlanan nüfusun hükümetlerin bütçeleri üzerinde oluşturacağı mali baskının hafifletilmesi adına oluşturulacak politikalara ek olarak özellikle Yunanistan ve İspanya gibi ülkelerde Covid-19 salgını sonrasında artış eğilimine geçen genç işsizliğin azaltılması için dijitalleşme ile uyumlu bölgesel politikaların oluşturulması önemli olacaktır. Özellikle dijital beceri eğitimleri verilmesine ve dijital işletmelerin desteklenmesine olanak sağlayacak, yenilikçi iş fikirleri ve startup'ların desteklenmesi için finansal destekleri arttıracak politikalar oluşturulabilir. Yine bu süreçte Avrupa Birliği fonları gibi uluslararası finansman kaynaklarından yararlanma stratejileri geliştirilebilir.

1.7. Çalışmanın Kısıtlılıkları ve Gelecekle İlgili Yönelimler

Çalışmada elde edilen sonuçlara bazı kısıtlılıklar çerçevesinde ulaşılmıştır. Bu kısıtlılıklardan ilki seçilen örneklem ve makroekonomik değişkenler ile ilgilidir. Analiz için sadece 29 adet OECD üyesi ülkeye ait 5 adet makroekonomik değişken seçilmiştir. İkincisi analizlerin sadece 2013-2022 tarihleri arasındaki 10 yıllık süreç için yapılmış olmasıdır. Son kısıtlılık ise; analiz için sadece k-ortalamlar kümeleme algoritmasının seçilmesi ve analizlerin WEKA yazılımında gerçekleştirilmiş olmasıdır. İleride yapılacak çalışmalarda örneklem olarak 38 OECD üyesi ülkenin tamamı örneklem olarak seçilebilir. 38 OECD üyesi ülkeye ait farklı makroekonomik değişkenler analize dahil edilebilir. Nitekim özellikle 2008 Küresel Krizi sonrasında Yunanistan ve İspanya gibi gelişmekte olan ülkelerde görülen genç işsizlik oranları düşünüldüğünde değişken olarak genç işsizlik oranı modele eklenebilir. Yıl aralığı genişletilerek analizler gerçekleştirilebilir. Öyle ki Amerika'da başlayan ve etkisi tüm dünyaya yayılan 2008 Küresel Krizi'nin OECD üyesi ülkelerin ekonomik gelişmişlikleri üzerindeki etkilerini değerlendirebilmek adına analizlere 2008 yılı ve öncesine ait veriler eklenebilir. Aynı zamanda Rusya-Ukrayna savaşının sebep olduğu uluslararası ekonomik zorlukların etkilerinin incelenmesi adına 2022 yılı sonra veriler de modele dahil edilebilir. Böylelikle meydana krizlerin ekonomik etkileri geniş çaplı olarak değerlendirilebilir. Bunlara ek olarak, hiyerarşik olmayan k-ortalamlar kümeleme algoritmasına ek olarak literatürde sıklıkla kullanılan hiyerarşik kümeleme yöntemlerinden Ward tekniği de analize dahil edilebilir. Böylelikle kümeler arasında oluşan benzerlik ve farklılıklar değerlendirilebilir. Son olarak ise; analizler için literatürde sıklıkla kullanılan SPSS yazılımına ek olarak bu

alıřmada olduėu gibi veri madenciliėine zel WEKA programı kullanılabilir. Bylelikle aynı kmeleme sonularına ulařılıp ulařılmayacaėı tespit edilerek literatre katkı sunulabilir.



2. BÖLÜM

KARAR AĞAÇLARI

ÖZET

Keşif sürecinin bir parçası olan veri madenciliğinde, istatistiki yöntemler kullanılarak çeşitli alanlarda biriken büyük veri açığa çıkarılmaktadır ve örgütsel amaçlar doğrultusunda kullanılabilecek hale getirilmektedir. Bu alanlardan biri de ekonomik gelişme düzeyini arttırmak isteyen ülkelerin mutlaka doğru politikalar belirlemesi gereken lojistik alanıdır. Bu çalışmanın amacı, ülkeleri ekonomik gelişme düzeylerine göre kümelere ayırmak ve ülkelerin ekonomik gelişme düzeylerinin farklılaşmasına neden olan lojistik göstergelerin belirlenmesidir. Bu amaç doğrultusunda öncelikle WEKA 3.8.6 yazılımında 29 OECD üyesi ülkeye ait GSYH, ihracat, ithalat, enflasyon ve işsizlik oranı değişkenlerinin 2019 yılı verileri ile k-ortalamalar kümeleme algoritması kullanılarak kümeleme analizi gerçekleştirilmiştir. Analizin ikinci kısmında 20 adet taşımacılık değişkeni kullanılarak karar ağaçları ile sınıflandırma yapılabilmesi için J48 algoritması kullanılmış ve ülkeler arasında farklılaşmaya neden olan lojistik göstergeler belirlenmiştir. Çalışma sonucunda ülkeler 4 kümeye ayrılmışlardır. Almanya ve ABD en gelişmiş ülkeler, Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore ve Birleşik Krallık gelişmiş ülkeler, Yunanistan, İspanya ve Türkiye ise gelişmekte olan ülkeler olarak belirlenmiştir. Geriye kalan 16 adet ülke ise az gelişmiş ülkeler olarak nitelendirilmiştir. Ülkelerin ekonomik gelişme düzeylerinin farklılaşmasına neden olan taşımacılık değişkenlerinin ise demiryolu altyapı yatırımı, GSYH başına düşen toplam iç ulaşım altyapı yatırımı, kişi başına düşen demiryolu altyapı yatırımı ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payı olduğu belirlenmiştir.

Anahtar Sözcükler: Veri madenciliği, Kümeleme analizi, K-ortalamalar algoritması, Karar ağaçları, OECD.

ABSTRACT

In data mining, which is a part of the discovery process, statistical methods are used to reveal big data accumulated in various fields and make it usable for organizational purposes. One of these areas is the logistics field, where countries that want to increase their level of economic development must determine the right policies. The aim of this study is to divide countries into clusters according to their economic development levels and to determine the logistic indicators that cause the economic development levels of countries to vary. For this purpose, firstly, cluster analysis was performed using the k-means clustering algorithm with the 2019 data of GDP, export, import, inflation and unemployment rate variables of 29 OECD member countries by using WEKA 3.8.6 software. In the second part of the analysis, the J48 algorithm was used to sort decision trees based on 20 transportation factors, and the logistic indicators that create differences between countries were identified. As a result of the study, countries were divided into 4 clusters. Germany and the USA were determined to be the most developed countries; Belgium, France, Japan, Canada, Italy, Mexico, Korea, and the United Kingdom as developed countries; and Greece, Spain, and Turkey as developing countries. The other 16 countries are described as underdeveloped countries. It has been determined that the transportation variables that cause the differences in the economic development levels of countries are railway infrastructure investment, total domestic transportation infrastructure investment per GDP, railway infrastructure investment per capita and the share of CO₂ emissions from international aviation bunkers in total CO₂ emissions.

Keywords: Data mining, Cluster analysis, K-means algorithm, Decision trees, J48 algorithm, OECD, Logistics.

GİRİŞ

Veri madenciliği, bir keşif sürecini ifade etmektedir. Bu keşif süreci ile birlikte daha önceden keşfedilmemiş potansiyel olarak yararlı olan bilgilerin istatistiksel yöntemler ile açığa çıkarılması mümkün olmaktadır. Bu kapsamda veri madenciliği sürecinin tanımlama, ilişkilendirme, kümeleme, sınıflandırma, tahmin ve öngörü gibi amaçları bulunmakta ve bu amaçlar doğrultusunda istatistiksel algoritmalar kullanılarak veri tabanlarında işlenmemiş halde bulunan veriler açığa çıkartılmaktadır. Bu veriler ise işlenerek örgütsel amaçlar doğrultusunda kullanılabilecek hale getirilmektedir.

Büyük verinin biriktiği alanlardan biri taşımacılık sektörüdür (Jamil et al., 2018: 230). Aslında taşımacılık sektörü veya genelleştirilecek olursa lojistik sektörü büyük verinin oluşmasına sebep olan endüstrilerdendir (Ohlhorst, 2012: 41). Hükümetler rota planlaması yapmak, akıllı ulaşım sistemleri geliştirmek ve trafiği kontrol etmek adına büyük veriden yararlanırken, özel sektör gerçekleştirdiği sevkiyatları kontrol etmek, navlun hareketinin optimizasyonunu sağlamak ve böylelikle rekabet avantajı elde etmek üzere büyük veriden yararlanabilmektedir (Naik & Joshi, 2017: 121). Lojistik sektöründe büyük verinin analizini mümkün kılan veri madenciliği yöntemleri kullanılarak gerçekleştirilebilecek uygulamalar ise şunlardır: Riskin bertaraf edilebilmesi için risk analizlerinin yapılması, yük akışının hızlandırılabilmesi için yük analizlerinin gerçekleştirilmesi, müşteri memnuniyeti için tedarikçi ve müşteri analizinin uygulanması, performansın artırılması için performans analizlerinin yapılması, lojistik merkezler için verimlilik analizlerinin gerçekleştirilmesi, çeşitli iyileştirmelerin yapılabilmesi için zayıf yönlerin tespit edilmesi ve doğru lojistik politikaların belirlenmesi (Akçetin et al., 2013).

Günümüzde özellikle ekonomik açıdan gelişmek isteyen ülkelerde lojistik sektöründe var olan eksikliklerin tespit edilerek doğru politikaların uygulanabilmesi ve hangi lojistik göstergelerin iyileştirilmesi gerektiğine dair bir yol haritasının belirlenmesi büyük önem taşımaktadır. Fakat lojistik sektöründe biriken büyük verinin analiz edilmesinin önemi göz önüne alındığında literatürde bu konuda büyük bir eksiklik olduğu saptanmıştır. Nitekim literatürde hizmet ve sanayi sektörlerinde en önemli değişkenlerin tespit edildiği çalışmalar (Albayrak & Yılmaz, 2009; De Oña et al., 2012; Aytekin, 2019 ve Abreu et al., 2023) mevcut iken; çeşitli endekslere etki eden en önemli değişkenlerin tespit edildiği çalışmalar da (Yakut & Korkmaz, 2020; Kutnjak et al., 2020; Timor & Yüzbaşı Künc, 2021 ve Özkan et al., 2023) bulunmaktadır. Bu çalışmalara ek olarak AB

ve Türkiye'nin çeşitli ekonomik göstergelerinin karşılaştırıldığı çalışmalara da (Gülpınar, 2008 ve Timor & Yüzbaşı Künc, 2021) literatürde rastlanmaktadır. Ayrıca literatürdeki çalışmalarda örneklem olarak çoğunlukla AB üyesi ülkelerin seçildiği fark edilmiştir. Dolayısı ile literatürde önce OECD ülkelerinin ekonomik gelişme düzeylerine göre kümeler ayrıldığı ardından da bu ülkelerin farklılaşmasına sebep olan taşımacılık göstergelerinin belirlendiği hiçbir çalışmaya rastlanmamıştır. Bu kapsamda bu çalışma hem örneklem seçimi hem de kümeleme analizi ile karar ağaçları yöntemlerinden oluşan iki adımlı bir analiz içermesi yönü ile literatürdeki çalışmalardan ayrılmaktadır. Literatürdeki mevcut eksikliği gidermek üzere bu çalışmanın amacı, ekonomik gelişme düzeylerine göre kümeler ayrılan ülkelerin farklılaşmasına neden olan en önemli lojistik göstergelerinin belirlenmesidir. Bu WEKA 3.8.6 yazılımında yapılan analizin ilk aşamasında 29 OECD üyesi ülkeye ait 5 adet makroekonomik değişkenin 2019 yılı verileri ile k-ortalamlar kümeleme algoritması kullanılarak kümeleme analizi gerçekleştirilmiştir. Böylece ülkeler çok gelişmiş, gelişmiş, gelişmekte olan ve az gelişmiş olarak kümeler ayrılmışlardır. Analizin ikinci aşamasında ise J48 algoritması kullanılarak karar ağaçları ile sınıflandırma yapılabilmesi için kümeleme analizi sonucunda elde edilen nominal hedef değişken ve tahminleyici olarak 29 OECD üyesi ülkeye ait 20 adet taşımacılık değişkeninin 2019 yılına ait nümerik verileri kullanılmıştır. Analiz sonucunda; Almanya ve ABD en gelişmiş ülkeler, Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore ve Birleşik Krallık gelişmiş ülkeler, Yunanistan, İspanya ve Türkiye ise gelişmekte olan ülkeler olarak belirlenmiştir. Geriye kalan 16 adet ülke (Avusturalya, Avusturya, Çek Cumhuriyeti, Estonya, Finlandiya, Macaristan, İrlanda, Letonya, Litvanya, Lüksemburg, Yeni Zelanda, Norveç, Polonya, Slovenya, İsveç, İsviçre) ise az gelişmiş ülkeler olarak nitelendirilmiştir. OECD ülkelerinin ekonomik gelişme düzeylerinde farklılığa sebep olan değişkenlerin ise ulaşım altyapısı, ulaşım altyapısına yapılan yatırım harcamaları ile enerji ve çevre ile ilgili göstergeler olduğu tespit edilmiştir. Nitekim çalışmadan elde edilen bu sonuçların literatürdeki eksikliği gidereceği ve ekonomik açıdan gelişmek isteyen ülkelerin politika belirleyicilerine hangi lojistik göstergelerin iyileştirilmesi gerektiğine dair bir yol haritası sunacağı düşünülmektedir.

2.1. Literatür Taraması

Karar ağaçları algoritmaları kullanılarak yapılan sınıflandırma çalışmalarından bazıları Tablo 2.1.'de gösterilmiştir. Tablo 2.1.'de görüldüğü üzere; karar ağaçları ile

yapılan sınıflandırma analizlerine dayalı çalışmalarda çeşitli göstergelere etki eden önemli değişkenlerin C4.5, C5.0, CHAID (Chi-squared Automatic Interaction Detector), CART (Classification and Regression Tree) ve rastgele orman algoritmaları kullanılarak bulunduğu belirlenmiştir.

Tablo 2.1. Karar ağaçları Algoritmaları Kullanılarak Yapılan Çalışmalar

Yazar-Yıl	Çalışmanın Başlığı	Veriler	Yöntem	Bulgular
(Gülpınar, 2008)	Avrupa Birliği Ülkeleri ile Türkiye'nin Ekonomik Göstergelerinin Karar Ağacı Yöntemi İle Karşılaştırılması	20 AB üyesi ve Türkiye'nin enflasyon oranları, işsizlik oranları, kur oranları, GSYH, ihracat, ithalat, toplam işgücü, sabit sermaye yatırımları ve nüfus yoğunluğu verileri kullanılmıştır.	Karar ağaçları algoritmalarından C4.5 kullanılmıştır.	Karar ağaçlarının görüntüsüne bakıldığında enflasyon, GSYH, ihracat ve işsizlik oranı değişkenlerinin kazanç oranları en yüksek değişkenler olduğu görülmüştür.
(Albayrak & Yılmaz, 2009)	Veri Madenciliği: Karar Ağacı Algoritmaları ve İMKB Verileri Üzerine Bir Uygulama	İMKB 100 endeksinde hizmet ev sanayi sektöründe faaliyet gösteren 173 işletmenin 2004-2006 yıllarına ait veriler kullanılmıştır.	Karar ağaçları algoritmalarından CHAID kullanılmıştır.	Hizmet ve sanayi sektörlerinde faaliyet gösteren firmaları birbirinden ayıran en önemli değişkenler stok devir hızı, işletme sermayesinin net satışlara oranı ve ekonomik rantabilite olarak bulunur.
(De Oña et al., 2012)	A Classification Tree Approach to Identify Key Factors of Transit Service Quality	2007 yılına ait anket verileri kullanılmıştır.	CART algoritması kullanılmıştır.	Otobüs taşımacılığı hizmet kalitesinde yakınlık, hız ve güvenlik faktörlerinin önemli olduğu tespit edilmiştir.
(Aytekin, 2019)	Mobilya Endüstrisinde İhracat Performansının Belirleyicilerinin Analizleri: Bulanık AHP ve Karar Ağacı Modellemesi	Türkiye'de mobilya sektöründe faaliyet gösteren 182 firma yöneticisine ve 14 akademisyene yapılan anketlerden toplanan veriler kullanılmıştır.	Bulanık AHP ve Karar Ağaçları.	Faktör ve konuların önem dereceleri AHP ile belirlenmiş ve en önemli faktör müşteri memnuniyeti olarak tespit edilmiştir. İhracatta öne çıkan faktörler karar ağaçları ile modellenmiştir.
(Yakut & Korkmaz, 2020)	İnsani Gelişmişlik Endeksinin Karar Ağacı Algoritmaları	79 ülkenin 2000-2017 yılları arasındaki İnsani	Karar ağaçları tekniklerinden	İnsani Gelişmişlik Endeksi'ne en fazla etki eden faktörlerin istihdam,


	ile Modellenmesi: BM’de Bir Uygulama 2010-2017 Dönemi	Gelişmişlik Endeksi verileri kullanılmıştır.	C5.O algoritması kullanılmıştır.	eğitim ve sağlık olduğu belirlenmiştir.
(Kutnjak et al., 2020)	Applying the decision tree method in identifying key indicators of the Digital Economy and Society Index (DESI).	28 Avrupa Birliği ülkesine ait 2018 yılı dijital ekonomi ve toplum endeksi verileri kullanılmıştır.	Karar ağaçları.	Hızlı geniş bant, internet kullanıcıları becerileri, iş dijitalleşmesi, işlem ve e-sağlık en önemli değişkenler olarak belirlenmiştir.
(Timor & Yüzbaşı Künc, 2021)	Ekonomik Gelişmişliği Etkileyen Bilgi Ekonomisi Değişkenlerinin Veri Madenciliği İle Belirlenmesi	34 Avrupa Birliği üye ülkesi ve Türkiye’nin işsizlik, GSYİH ve ihracat ithalat oranı verileri ve 34 bilgi ekonomisi değişkeni kullanılmıştır.	K-ortalamlar kümeleme yöntemi ve karar ağaçları C5.0 algoritması.	Kümeleme analizi sonucunda düşük, orta ve yüksek olarak 3 farklı ekonomik seviye grubu elde edilmiştir. Ekonomik seviyelerine göre kümelenen ülkeleri ayıran en önemli bilgi ekonomisi değişkenlerinin eğitim ve AR-GE olduğu tespit edilmiştir.
(Özkan et al., 2023)	Ülkelerin Gelişmişlik Düzeylerinin Karar Ağacı ve Rastgele Orman Yöntemleriyle Tahmin Edilmesi.	193 ülkeye ait 26 değişkenden oluşan Dünya Gelişmişlik İndeksi verileri kullanılmıştır.	Karar ağaçları ve rastgele orman yöntemleri.	Ekonomik gelişmişlik üzerinde en etkili değişkenlerin ergen doğurganlık hızı, toplam doğurganlık oranı ve tarım, orman ve balıkçılığın GSYH içerisindeki payı olduğu belirlenmiştir.
(Abreu et al., 2023)	A decision tree model for the prediction of the stay time of ships in Brazilian ports.	Brezilya limanlarındaki ana kargo hareketlerine ilişkin 2018 yılı verileri kullanılmıştır.	Rastgele orman yöntemleri.	Coğrafi özelliklerin ve kargo özelliklerinin kalış süresini etkileyen faktörler oldukları belirlenmiştir.

2.2. Araştırma Metodolojisi ve Veri Seti

2.2.1. Veri madenciliği süreci ve yöntemleri

Eksik, belirsiz ve önceden bilinmeyen fakat potansiyel olarak yararlı bilgileri çıkarma sürecine veri madenciliği denir (Wu et al., 2012: 68) . Bilgi teknolojisinin doğal evriminin bir sonucu olarak görülen veri madenciliği, bir keşif sürecidir. Bu keşif sürecinin asıl amacı; büyük miktarda veriden istatistiksel olarak anlamlı desenleri ortaya çıkarmaktır (Zaki & Wong, 2003: 2; Han et al., 2012: 2-8; Larose & Larose, 2014: 2). Yeni bir bilgi işleme teknolojisi olan veri madenciliği sürecinin temel amacı; veri

tabanlarında yer alan çok sayıda veriyi ayıklamak, dönüştürmek ve analiz etmektir (Wu et al., 2012: 68). Bu kapsamda çeşitli alanlarda uygulanan çoğu veri madenciliği sürecinin genel amaçları ve görevleri şunlardır: Veri işleme, tanımlama, tahmin, öngörü, ilişki, sınıflandırma, kümeleme, bağlantı analizi, veri görselleştirme ve keşfedici veri analizi (Goebel & Gruenwald, 1999: 22; Larose & Larose, 2014: 14). Bahsedilen amaçları ve görevleri gerçekleştiren veri madenciliği süreci ile dijital ortamda ham halde bulunan veriler işlenerek örgütsel amaçlar için kullanılabilecek hale getirilir (Cemaloğlu & Duykuluoğlu, 2020: 98) Bunun için ise çeşitli veri madenciliği yöntemlerine ihtiyaç duyulmaktadır. Şekil 2.1.'de veri madenciliği yöntemleri gösterilmiştir:



Şekil 2.1. Veri Madenciliği Yöntemleri (Polat, 2021: 116).

Şekil 2.1.'de görüldüğü üzere veri madenciliği yöntemleri temel olarak tahmin edici ve tanımlayıcı yöntemler olarak ikiye ayrılmaktadır. Araştırmacılar amaçlarına uygun olarak hem tahmin edici hem de tanımlayıcı yöntemleri tercih edebilmektedirler.

2.2.1.1. Tahmin edici yöntemler

Tahmin edici yöntemler, önceden gözlemlenmeyen bir sistemin analiz edilerek sistem davranışlarının tahmin edilmesine dayanan bir model inşa edilmesini sağlar (Mints, 2017: 48). Sonuçları bilinen veriler yardımı ile bir model inşa edilir ve bu model yardımı ile sonuçları bilinmeyen veriler için tahmin geliştirilir. Örneğin; bankalar geçmiş dönemde kredi verdiği kişinin bilgilerinden yararlanarak kredi alan müşterinin bu krediyi ödeyip ödeyemeyeceğini tahmin edebilir (Akpınar, 2000). Tahmin edici yöntemler temel olarak regresyon ve sınıflandırma analizlerinden oluşmaktadır (Ramageri, 2010: 302-303).

Sınıflandırma yöntemi, en yaygın kullanılan veri madenciliği yöntemi olarak karşımıza çıkmaktadır (Ramageri, 2010: 302; Berry & Linoff, 2004: 8; Larose & Larose, 2014: 148). Sınıflandırma yöntemi, tahmine dayalı olarak gerçekleştirilen modelleme türlerinden biri olarak karşımıza çıkmaktadır. Sınıflandırma yöntemi ile yeni nesnelerin önceden tanımlanan sınıflara ataması gerçekleştirilmektedir (Zaki & Wong, 2003: 16). Tahminsel bir veri madenciliği tekniği olan sınıflandırma yöntemi ile daha önce görülmeyen kayıtların önceden eğitilen sınıflara ataması gerçekleştirilir (Berry & Linoff, 2004: 8-9; Takçı, 2020: 91). Bu durum sınıflandırma yönteminin denetimli öğrenme (supervised learning) işlevine sahip olduğunu göstermektedir (Zaki & Wong, 2003: 16; Witten et al., 2016: 40; Aggarwal, 2015; Gera & Goel, 2015: 22). Denetimli öğrenme işlevine sahip olan sınıflandırma yöntemi, önceden etiketi belli olan verilerin eğitilmesi ile etiketlenmemiş verilerin sınıfının tahmin edilebilmesini mümkün kılmaktadır (Gera & Goel, 2015: 22; Aggarwal, 2015: 285).

Sınıflandırma yönteminin tanımlarından da anlaşılacağı üzere sınıflandırma problemlerinde eğitim verisi ve test verisi bulunmaktadır. Eğitim verisi ile diğer grupların yapısı keşfedilmeye çalışılır (Aggarwal, 2015: 285; Takçı, 2020: 92). Aslında sınıflandırma yönteminin denetimli öğrenme işlevine sahip olmasının nedeni de budur. Eğitim verisi kullanılarak diğer grupların yapısı keşfedilmeye çalışıldığı için sınıflandırma yönteminin denetimli öğrenme işlevine sahip olduğu söylenir (Aggarwal, 2015: 285). Denetimli öğrenmeye sahip sınıflandırma yönteminde eğitim verileri (sınıf etiketi belli olan veriler) kullanılarak sınıf etiketi bilinmeyen verilerin sınıfı tahmin edilebilir (Han et al., 2012: 18). Kısacası sınıflandırma problemlerinde oluşturulan model, eğitim verisi ile eğitilmekte ve test verileri ile de değerlendirilmektedir (Aggarwal, 2015: 285; Takçı, 2020: 92). Test verilerinin başarı oranına bakılarak ilgili kavramın ne kadar iyi öğrenildiği anlaşılabilir (Witten et al., 2016: 40).

Tahmin edici yöntemler içerisinde yer alan ve birçok problemin çözümünde kullanılan regresyon analizi ise, bir bağımlı değişken ile bağımsız değişkenler arasındaki ilişkinin tahmin edilmesi için kullanılan istatistiksel bir tekniktir (Ramageri, 2010: 305; Maheshwari, 2015: 77; Mints, 2017: 48; Takçı, 2020: 139). Bir değişkenin önceden aldığı değerden yola çıkılarak bilinmeyen bir değişkenin değeri tahmin edilmeye çalışılır (Cemaloğlu & Duykuluoğlu, 2020: 240). Denetimli öğrenme işlevine sahiptir ve sayısal/sürekli bir hedef değeri tahmin etmek için kullanılır (Gera & Goel, 2015).


2.2.1.1.1. Karar ağaçları

Sınıflandırma yöntemleri içerisinde en çok tercih edilen yöntemlerden biri karar ağaçlarıdır. Tahmin edici özelliğe sahip sınıflandırma yöntemlerinden biri olan karar ağaçları denetimli öğrenme işlevine sahiptir (Chen et al., 1996: 875). Karar ağaçları “regresyon ağaçları” ve “sınıflandırma ağaçları” olarak da bilinmektedir (Williams, 2011: 205). Karar ağaçları 1980’li yıllarda geliştirilmiş ve geliştirildikleri günden bugüne kadar da klasik makine öğrenmesi algoritmalarının ve tabi ki veri madenciliği algoritmalarının en önemli unsurları arasında yer almıştır (Williams, 2011: 205; Cemaloğlu & Duykuluoğlu, 2020: 383). Günümüzde finansal analiz, moleküler biyoloji, tıp ve imalat gibi çeşitli alanlarda sınıflandırma amacı ile kullanılan karar ağaçları (Han et al., 2012: 301) aslında en fazla kullanılan sınıflandırma yöntemlerindendir (Gorunescu, 2011: 159; Maheshwari, 2015: 63; Takçı, 2020: 93). Bunun birkaç sebebi vardır: Öncelikle karar ağaçları kullanılarak yapılan analizlerde verilerin takibi, anlaşılması ve açıklanması kolaydır (Williams, 2011: 205; Gorunescu, 2011: 183; Ersöz, 2019: 70). Kısacası karar ağaçları basit bir yapıya sahiptir ve bu durum araştırmacının ilgili modeli daha rahat kavramasına yardımcı olur (Fayyad et al., 1996: 46). Aynı zamanda karar ağaçları veri tabanı sistemlerine kolayca entegre olabilen, ucuz, kolay ve güvenilir bir tekniktir (Akpınar, 2000: 14). Bu avantajlarına ek olarak karar ağaçları kullanılarak yapılacak analizlerde hem kategorik hem de sürekli verilerin sınıflandırılabilmesi mümkündür (Fayyad et al., 1996: 48; Gorunescu, 2011: 183; Teksin & Turanlı, 2018: 36). Kısacası karar ağaçları esnek ve anlaşılabilir bir yöntemdir (Gorunescu, 2011: 159). Son olarak karar ağaçlarının sınıflandırma doğruluklarının diğer sınıflandırma yöntemleri ile rekabet edebilecek düzeyde olduğu da söylenebilir (Gorunescu, 2011: 183; Maheshwari, 2015: 63). Fakat genel olarak yüksek doğruluğa sahip olan karar ağaçlarının sınıflandırma başarısının araştırmacının elinde bulunan verilere bağlı olacağı da unutulmamalıdır (Han et al., 2012: 331).

Karar ağaçları, ağaç benzeri bir yapıda olup kök boğumundan başlayan bir akış şemasına benzemektedir. Bu doğrultuda karar ağaçları en üstte yer alan “kök” (root) veya “kök boğumu” olarak adlandırılan bir merkez noktasından başlar (Williams, 2011: 206; Han et al., 2012: 330; Larose & Larose, 2014: 165; Gera & Goel, 2015: 23). Merkez noktasındaki kök boğumundan başlayan “dallarda” (branch) sonuç değişkenine doğru bir yol izleyen “karar boğumları” (leaf nodes) yer alır. Nihai değişkene ulaşana kadar karar boğumları devam eder (Larose & Larose, 2014: 165). Karar ağaçlarında son aşamada

sınıf etiketlerini gösteren boğumlar bulunur. Bu boğumlara “uç boğum” veya “nihai boğum” (terminal node) adı verilir. Uç boğum veya nihai boğumdan hemen önce ise “dahili boğum” ya da “iç boğum” (internal node) adı verilen boğumlar yer alır (Han et al., 2012:301-303).

Basit bir karar ağacı örneği Şekil 2.2.’de gösterilmiştir. Şekil 2.2.’ye göre kök boğumundan (root) başlayan karar ağaçları, tek bir gövdeden iki veya daha fazla dala (branch) ayrılan boğumlara (node) ayrılır. Karar ağacında yer alan her bir boğumun ise daha fazla boğuma bölündüğü veya nihai düğüm (terminal node) ile sonuçlandığı görülmektedir (Williams, 2011: 206).



Şekil 2.2. Basit bir Karar Ağacının Yapısı (Williams, 2011: 206).

Veri madenciliğinde sınıflandırma yöntemleri içerisinde yer alan karar ağaçlarını oluşturabilmek için çeşitli algoritmalar geliştirilmiştir. Bu algoritmalarından bazıları şunlardır; ID3, C4.5, C5.0 ve classification and regression trees (CART), (Chi-Squared Automatic Interaction Detector (CHAID) algoritması (Akpınar, 2000: 16; Han et al., 2012: 332; Larose & Larose, 2014: 168- 183; Teksin & Turanlı, 2018: 36). Araştırmacılar, araştırma amaçlarına uygun olacak şekilde bahsedilen algoritmaları kullanarak analizlerini gerçekleştirebilmektedirler.

2.2.1.2 Tanımlayıcı yöntemler

Denetimli öğrenme işlevine sahip olan ve hedef değeri tahmin etmeye odaklanan tahmin edici yöntemlerin aksine denetimsiz öğrenme işlevine sahip tanımlayıcı (betimleyici) yöntemler daha çok verilerin iç yapısına ve veriler arası ilişkilere odaklanmaktadır (Williams, 2011: 175). Veriler arasındaki gizli ilişkileri inceleyen tanımlayıcı yöntemlerde çeşitli kuralların tanımlanması ve türetilmesi söz konusudur (Mints, 2017: 48). Kısacası veriler arasındaki örüntüler keşfedilmeye çalışılır ve geleceğe

yönelik tahmin gerçekleştirilmez. Örneğin; belirli bir gelire sahip, iki veya daha fazla arabası bulunan bir aile ile gelir düzeyi daha düşük ve çocuğu olmayan bir ailenin satın alma örüntülerinin birbirlerine benzediği tanımladığı yöntemler yardımı ile belirlenebilir (Akpınar, 2000: 5). Veri madenciliğinde tanımlayıcı yöntemler içerisinde kümeleme analizi ve ilişkilendirme analizi yer almaktadır (Williams, 2011: 172).

Kümeleme analizi ile heterojen nitelikteki verilerin homojen alt gruplara ayrılması sağlanır (Collier et al., 1998: 19). Bir veri setinin çok benzer alt gruplara ayrılması kümeleme analizini ifade eder (Aggarwal, 2015: 153). Kümeleme analizinin uygulanabilmesi için ise farklı algoritmalar geliştirilmiş ve bunlar hiyerarşik ve hiyerarşik olmayan yöntemler olarak iki başlık altında toplanmıştır. Hiyerarşik ve hiyerarşik olmayan yöntemler olarak ikiye ayrılan kümeleme tekniklerinden hangisinin seçileceği ise araştırmacının problemine bağlıdır (Pujari et al., 2001: 20). Nitekim araştırmacının verilerin kaç kümeye ayrılacağına ilişkin bir bilgisi ve öngörüsü bulunmuyor ise hiyerarşik yöntemlerin tercih edilmesi gerekir iken (Takçı, 2020: 153); araştırmacının verilerin kaç kümeye ayrılacağına dair bilgisinin olduğu ve küme sayısına karar verdiği durumlarda hiyerarşik olmayan kümeleme yöntemlerinin tercih edilmesi doğru olacaktır (Turanli et al.; 2006: 99).

Tanımlayıcı yöntemler içerisinde bulunan ilişkilendirme analizi ise veri madenciliğinin temel yöntemlerinden biridir ve farklı araştırmacılar tarafından sıklıkla kullanılmaktadır. (Williams, 2011: 171-172). İlişkilendirme analizlerini birliktelik kuralları ve sıralı dizin analizleri olmak üzere ikiye ayırmak mümkündür. Birliktelik kuralları, veri madenciliği yöntemleri içerisinde oldukça popüler olup olayların birlikte meydana gelme olasılıklarını ortaya koyar iken (Özkan, 2020: 217); sıralı dizin analizleri ile belirli bir zaman içerisinde gerçekleşen olaylar arasındaki örüntülerin ortaya koyulması söz konusudur (Takçı, 2020: 161).

2.2.2. Veri seti ve veri dönüşümü

Çalışmada analizlerin gerçekleştirilebilmesi için OECD üyesi olan ülkelere ait makroekonomik değişkenler ve taşımacılık verileri <https://stats.oecd.org/> web sitesinden 4 Haziran 2023- 10 Haziran 2023 tarihleri arasında elde edilmiştir. Ancak veri tabanlarında ham halde bulunan veriler eksik veya aykırı değerler içerebilmektedir (Larose & Larose, 2014: 17). <https://stats.oecd.org/> web sitesinden elde edilen taşımacılık verilerinin de çok büyük kısmında çoğu ülkenin verisinin ya hiç olmadığı ya da eksik

olduğu tespit edilmiştir. Bu doğrultuda ilgili web sitesinde taşımacılık verileri hiç olmayan veya eksik olan ülkeler analize dahil edilmemiştir. Ayrıca Türkiye'nin verilerinin eksik olduğu değişkenlerin de analize dahil edilmemesi kararlaştırılmıştır. Bu kapsamda analiz için taşımacılık verilerinin yayınlandığı son yıl olan 2019 yılı seçilmiş ve 2019 yılında eksik verisi bulunmayan 29 adet OECD üyesi ülkeye ait 5 adet makroekonomik değişken ve 20 adet taşımacılık değişkenine ilişkin ikincil veriler elde edilmiştir. Bu doğrultuda analizin gerçekleştirilebilmesi için seçilen 29 adet OECD üyesi ülke Tablo 2.2.'de, 5 adet makroekonomik değişken Tablo 2.3.'de ve taşımacılık değişkenleri de Tablo 2.4.'de gösterilmiştir.

Tablo 2.2. Kümeleme ve Karar Ağacı Analizleri İçin Seçilen OECD Üyesi Ülkeler

Avusturalya	Çek Cumhuriyeti	Almanya	İtalya
Avusturya	Estonya	Yunanistan	Japonya
Belçika	Finlandiya	Macaristan	Kore
Kanada	Fransa	İrlanda	Letonya
Litvanya	Lüksemburg	Meksika	Yeni Zelanda
Norveç	Polonya	Slovenya	İspanya
İsveç	İsviçre	Türkiye	Birleşik Krallık
Amerika			

Tablo 2.3. Kümeleme Analizinde Kullanılan Makroekonomik Değişkenler

Makroekonomik Değişkenler	Birim
GSHY	Dolar (\$)
İhracat (Mevsimsel etkiden arındırılmış)	Dolar (\$)
İthalat (Mevsimsel etkiden arındırılmış)	Dolar (\$)
Tüketici Fiyatları, Yıllık Enflasyon (Bir önceki yılın aynı dönemine göre)	Yüzde (%)
İşsizlik Oranı (15-64 yaş)	Yüzde (%)

Tablo 2.4. Karar Ağaçları ile Yapılan Analizde Kullanılan Taşımacılık Değişkenleri

Ulaşım Altyapısı	Yatırım Harcamaları	Değişken Adı	Kod	Birim
		Toplam İç Ulaşım Altyapı Yatırımları	YH1	Euro
		Karayolu Altyapı Yatırımı	YH2	Euro
		Demiryolu Altyapı Yatırımı	YH3	Euro
	Güvenlik	Yüz Bin Kişi Başına Düşen Yol Ölümleri	G1	-
	Ekonomik ve Sosyal	Taşımacılık Sektörünün Katma Değer Payı	ES1	-
		Taşımacılık İçin Hanehalkı Harcamalarının Toplam Hanehalkı Harcamaları İçerisindeki Payı	ES2	-
		Karayolu Altyapı Yatırımlarının Toplam İç Ulaşım Altyapı Yatırımları İçerisindeki Payı	UA1	-
		Demiryolu Altyapı Yatırımlarının Toplam İç Ulaşım Altyapı Yatırımları İçerisindeki Payı	UA2	-
		Kişi Başına Düşen Karayolu Altyapı Yatırımı	UA3	Dolar
		Kişi Başına Düşen Demiryolu Altyapı Yatırımı	UA4	Dolar

Performans Göstergeleri	Ulaşım Altyapısı	Kişi Başına Düşen Toplam İç Ulaşım Altyapı Yatırımı	UA5	Dolar
		GSYH Başına Düşen Karayolu Altyapı Yatırımı	UA6	-
		GSYH Başına Düşen Demiryolu Altyapı Yatırımı	UA7	-
		GSYH Başına Düşen Toplam İç Ulaşım Altyapı Yatırımı	UA8	-
	Enerji ve Çevre	Mevcut ABD Doları Cinsinden GSYH'nin Bir Milyon Birimi Başına Düşen Ton Cinsinden Taşımacılıktan Kaynaklanan CO ₂ Emisyonları	EC1	-
		Ton Cinsinden Kişi Başına Düşen Taşımacılıktan Kaynaklanan CO ₂ Emisyonları	EC2	-
		Uluslararası Havacılık Sığınaklarından Kaynaklanan CO ₂ Emisyonlarının Toplam CO ₂ Emisyonları İçerisindeki Payı	EC3	-
		Karayolundan Kaynaklanan CO ₂ Emisyonlarının Toplam Taşımacılıktan Kaynaklanan CO ₂ Emisyonları İçerisindeki Payı	EC4	-
		Demiryolundan Kaynaklanan CO ₂ Emisyonlarının Toplam Taşımacılıktan Kaynaklanan CO ₂ Emisyonları İçerisindeki Payı	EC5	-
		CO ₂ Emisyonlarının Toplam Taşımacılıktan Kaynaklanan CO ₂ Emisyonları İçerisindeki Payı	EC6	-

29 OECD üyesi ülkenin 2019 yılına ait 5 adet makroekonomik değişkene ait 145 veri ve 20 adet taşımacılık değişkenine ait 580 adet veri <https://stats.oecd.org/> veri tabanından elde edildikten sonra her bir özneliğe eşit ağırlık verilebilmesi ve öğrenme süresinin minimuma indirilebilmesi için normalizasyon işlemine tabi tutulmuştur (Han et al., 2012: 113-114). Bu kapsamda çalışmada yapay sinir ağlarında en iyi sonucu veren (Yavuz & Deveci, 2012) D_min_max yöntemi uygulanmıştır. Buna göre verilerin [0,1-0,9] değerleri arasına indirgenebilmesi için Eşitlik 2.1'den yararlanılmıştır:

$$x' = 0.8 * \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0.1 \quad (2.1)$$

Eşitlik 2.1'de;

x'= Normalize edilmiş veri,

x_i= Girdi değeri,

x_{min}= Girdi seti içindeki en küçük değer,

x_{max}= Girdi seti içindeki en büyük değerdir.

2.3. Uygulama ve Bulgular

Bu çalışmanın amacı; ekonomik gelişme düzeylerine göre kümelerle ayrılan OECD üyesi ülkeleri birbirinden ayıran en önemli lojistik göstergelerinin belirlenmesidir. Bu nedenle analiz iki aşamadan oluşmuştur. Analizin ilk aşamasında ülkelerin ekonomik gelişmişliklerine göre gruplanması amacı ile kümeleme analizi gerçekleştirilmiştir.

Nitekim günümüzde veri tabanlarında büyük miktarda veri bulunmaktadır. Büyük miktarda verinin yer aldığı bu veri tabanlarında yapılacak kümeleme analizinin genellikle bir ön adım olarak uygulanması oldukça yararlıdır (Ramageri, 2010: 302; Larose & Larose, 2014: 210; Aggarwal, 2015: 153). Çünkü, büyük miktarda veri, istatistiki tekniklerin uygulanmasını zorlaştırmakta ve verilerin gruplandırılması gerekliliğini ön plana çıkarmaktadır (Koldere Akın, 2022: 13). Aynı zamanda veri madenciliği süreci büyük verinin özetlenmesi ile ilgili bir kavramdır ve kümeleme analizi de büyük verinin özetlenmesine yardımcı olur (Aggarwal, 2015: 153). Ayrıca kümeleme analizi gerçekleştirmek tahmin yeteneğini de arttırmaktadır (Collier et al., 1998: 19). Bu çalışmada da karar ağaçları ile yapılan ikinci analizde ülkelerin ekonomik gelişmişlik seviyesini gösteren nominal girdi değişkeni oluşturmak üzere bir ön analiz olarak kümeleme analizi tercih edilmiştir. Bu kapsamda 29 OECD üyesi ülkeye ait 5 adet makroekonomik değişkenin 2019 yılına ait verileri ile WEKA 3.8.6 yazılımında kümeleme analizi gerçekleştirilmiştir. Kümeleme analizi gerçekleştirilirken anlaşılma ve uygulama kolaylığından dolayı hiyerarşik olmayan yöntemler içerisinde yer alan k-ortalamlar algoritması tercih edilmiştir. Algoritmanın uygulanabilmesi için ise öncelikle küme sayısı belirlenmiştir. Küme sayısı, pratik olarak “n” örneklem sayısı ve “k” küme sayısı olmak üzere (2.2) numaralı denklem ile tespit edilmiş (Everitt, 1974: 122) ve 4 olarak bulunmuştur.

$$k \cong (n / 2)^{1/2} \quad (2.2)$$

Küme sayısının belirlenmesinin ardından nihai veriler seti arff dosya tipine dönüştürülmüş ve WEKA 3.8.6 yazılımında kümeleme analizi gerçekleştirilmiştir. Kümeleme analizi sonuçları Tablo 2.5.de, kümelere ait son küme merkezleri ise Tablo 2.6.’da gösterilmiştir.

Tablo 2.5. 2019 Yılına Ait Kümeleme Analizi Sonuçları

Yıl	Küme 0	Küme 1	Küme 2	Küme 3
2019	Yunanistan, İspanya, Türkiye	Almanya, ABD	Avusturalya, Avusturya, Çek Cumhuriyeti, Estonya, Finlandiya, Macaristan, İrlanda, Letonya, Litvanya, Lüksemburg, Yeni Zelanda, Norveç, Polonya, Slovenya, İsveç, İsviçre	Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore, Birleşik Krallık


Tablo 2.5.’de görüldüğü üzere kümeleme analizi sonucunda 29 adet OECD üyesi ülkenin %10’u küme 0’da %7’si küme 1’de, %55’i küme 2’de ve %28’i küme 3’te yer

almıştır. Tablo 2.6.'daki son küme merkezleri incelendiğinde; Almanya ve ABD'nin yer aldığı küme 1'in diğer kümelerle göre en yüksek GSYH, ihracat ve ithalat değerlerine ve en düşük işsizlik oranına sahip olduğu belirlenmiştir. Bu sonuç Almanya ve ABD'nin çok gelişmiş ülkeler olduklarını göstermiştir. Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore ve Birleşik Krallık'ın yer aldığı küme 3'ün gelişmiş ülkeleri barındırdığı görülmüştür. Yunanistan, İspanya ve Türkiye'nin yer aldığı küme 0'ın ise gelişmekte olan ülkeleri temsil ettiği ve bu kümede yer alan ülkelerin en yüksek işsizlik ve enflasyon oranına sahip ülkeler oldukları saptanmıştır. Geriye kalan 16 ülkenin yer aldığı Küme 2'nin ise diğer kümelerle göre nispeten daha az gelişmiş ülkeleri temsil ettiği belirlenmiştir. Özetle; bir ön analiz olarak gerçekleştirilen kümeleme analizi sonucunda 2 ülke en gelişmiş, 8 ülke gelişmiş, 3 ülke gelişmekte olan ve 16 ülke de az gelişmiş olarak nitelendirilmiştir.

Tablo 2.6. 2019 Yılına Ait Son Küme Merkezleri

Küme	GSYH	İhracat	İthalat	Enflasyon	İşsizlik Oranı
Küme 0	0.1566	0.1829	0.1636	0.3746	0.7836
Küme 1	0.5885	0.8613	0.6966	0.1738	0.1728
Küme 2	0.1143	0.1525	0.1299	0.1881	0.2436
Küme 3	0.2016	0.3472	0.2685	0.1621	0.2774

Analizin ikinci aşamasında ekonomik gelişmişlik düzeylerine göre kümelerle ayrılan ülkeler arasında farklılığa sebep olan lojistik göstergelerin belirlenebilmesi için veri madenciliğinin sınıflandırıcı yöntemlerinden karar ağaçları kullanılmıştır. Karar ağaçlarının oluşturulmasında ise sahip olduğu üstün özellikler dikkate alınarak J. Ross Quinlan tarafından geliştirilen C5.0 algoritmasının WEKA versiyonu olan J48 algoritması tercih edilmiştir. Karar ağaçları oluşturulmasında 29 OECD üyesi ülkeye ait 20 adet taşımacılık değişkeninin 2019 yılına ait nümerik verileri tahminleyici olarak yer alır iken; nominal hedef değişken olarak ise ekonomik gelişmişliğine göre gruplanan ülkeler kullanılmıştır. Ekonomik gelişmişlik olarak belirlenen nominal hedef değişkende 2 ülke en gelişmiş, 8 ülke gelişmiş, 3 ülke gelişmekte olan ve 16 ülke de az gelişmiş olarak nitelendirilmiştir. Nominal ve nümerik değişkenler arff dosya formatında WEKA 3.8.6 yazılımına yüklendiğinde ortaya çıkan arayüz görüntüsü Şekil 2.3.'de yer almaktadır:



Şekil 2.3. WEKA Arayüz Ekranı


Nominal ve nümerik değişkenlerin WEKA yazılımına yüklenmesinin ardından karar ağaçlarının oluşturulması için sınıflandırma bölümünden J48 algoritması seçilmiştir. J48 algoritması, C4.5 ve onun güncellenmiş hali olan C5.0 algoritmasının WEKA yazılımındaki karşılığıdır. Bu algoritmanın araştırmacılara sağladığı önemli avantajlar bulunmaktadır:

- C5.0 algoritmasında bağımsız değişkenler kategorik ve sıralı, bağımlı değişken nominal/sıralı olabilmektedir (Teksin & Turanlı, 2018: 37).
- Parametrik olmayan bir yöntem olması C5.0 algoritmasının araştırmacılar tarafından sıklıkla tercih edilmesini sağlar. Çünkü normallik ve doğrusallık gibi parametrik varsayımların varlığına ihtiyaç duyulmadan analizler gerçekleştirilebilir (Teksin & Turanlı, 2018: 37).

Bahsedilen avantajlarından ötürü karar ağaçlarının oluşturulmasında J48 (C5.0) algoritması tercih edilmiştir. Bu algoritmanın uygulanmasında en yüksek sınıflandırma başarısının elde edilebilmesi için yapılan denemeler sonucunda en iyi sonucu verdiği için 580 adet taşımacılık verisinin %55'i (319 adet) eğitim ve %45'i (261 adet) test verisi olarak rastgele ayrılmıştır. Bu durumda sınıflandırma başarısının %76,9 olduğu belirlenmiştir. Eğitim ve test veri kümelerinin sınıflandırma başarıları Tablo 2.7.'de, J48 algoritması ile yapılan analiz sonucunda ortaya çıkan arayüz ekranı da Şekil 2.4.'de yer görülmektedir.


Tablo 2.7. Eğitim ve Test Veri Kümelerinin Sınıflandırma Başarıları

Eğitim Veri Kümesi (%)	Test Veri Kümesi (%)	Sınıflandırma Başarısı (%)
5	95	53.5714
10	90	57.6923
15	85	44
20	80	39.1304
25	75	45.4545
30	70	45
35	65	42.1053
40	60	41.1765
45	55	37.5
50	50	50
55	45	76.9231
60	40	58.3333
65	35	60
70	30	55.5556
75	25	71.4286
80	20	66.6667
85	15	50
90	10	66.6667
95	5	0

**Şekil 2.4.** J48 Algoritmasının Uygulanması Sonucunda WEKA Arayüz Ekranı

Analiz sonucunda elde edilen karar ağaçlarına ait dendogram Şekil 2.5.'de gösterilmiştir. Dendograma göre, YH3 (Demiryolu altyapı yatırımı) değişkeni karar ağacının kök boğumunu oluşturmaktadır. Bu kök boğumu ise iki dala ayrılmıştır. Nitekim $YH3 \leq 0.32397$ ise UA8 (GSYH başına düşen toplam iç ulaşım altyapı yatırımı) değişkeninin oluşturduğu boğum, $YH3 > 0.32397$ ise UA4 (kişi başına düşen demiryolu altyapı yatırımı) değişkeninin oluşturduğu boğum ortaya çıkmıştır. UA4 en gelişmiş ve

gelişmiş ülkeleri birbirinden ayıran taşımacılık değişkeni olmuştur. Öyle ki $UA4 \leq 0.277296$ ise nihai düğüm en gelişmiş ülkelerden, $UA4 > 0.277296$ ise nihai düğüm gelişmiş ülkelerden oluşmuştur. $UA8 > 0.233314$ olduğu durumda nihai düğüm az gelişmiş ülkelerden oluşur iken, $UA8 \leq 0.23331$ olduğunda EC3 (uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payı) düğümü oluşmuştur. Son olarak ise EC3 düğümü iki dala ayrılarak gelişmiş ve gelişmekte olan ülkelere ayrılmıştır. Nitekim $EC3 \leq 0.316113$ ise nihai düğüm gelişmiş ülkelerden, $EC3 > 0.316113$ ise de nihai düğüm gelişmekte olan ülkelere oluşmuştur.



Şekil 2.5. Karar Ağaçlarına Ait Dendrogram

2.4. Tartışma

OECD ülkelerinin ekonomik gelişme düzeylerine göre kümeler ayrılmasını ve bu kümeler arasında farklılığa sebep olan taşımacılık göstergelerinin belirlenmesini amaçlayan bu çalışmada elde edilen ilk önemli bulgu ülkelerin dört kümeye ayrılmasıdır. Nitekim bu kümeler içerisinde en gelişmiş ülkeleri Almanya ve ABD temsil eder iken; gelişmiş ülkeleri Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore ve Birleşik Krallık temsil etmiştir. Yunanistan, İspanya ve Türkiye ise gelişmekte olan ülkeler olarak belirlenmiştir. Geriye kalan 16 adet ülkenin (Avusturalya, Avusturya, Çek Cumhuriyeti, Estonya, Finlandiya, Macaristan, İrlanda, Letonya, Litvanya, Lüksemburg, Yeni Zelanda, Norveç, Polonya, Slovenya, İsveç, İsviçre) ise az gelişmiş ülkeler olarak birlikte küme oluşturdukları saptanmıştır. Bu sonuçlar 2019 yılı için yaptığı kümeleme analizi sonucunda Almanya'yı Avrupa Birliği ülkeleri içerisinde ortalamanın üzerinde bir ekonomiye sahip olarak belirler iken; Yunanistan, İspanya ve Türkiye'nin gelişmekte olan ülkeler olduğunu tespit eden Timor & Yüzbaşı Künc (2021) ile benzerdir.

Çalışmada elde edilen bir diğer bulgu ise; demiryolu altyapı yatırımı, kişi başına düşen demiryolu altyapı yatırımı, GSYH başına düşen toplam iç ulaşım altyapı yatırımı ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının kümeler arasında farklılığa sebep olduğudur. Ayrıca demiryolu altyapı yatırımının en gelişmiş ve gelişmiş ülkelerde gelişmekte olan ve az gelişmiş ülkelere kıyasla yüksek olduğu saptanmıştır. Öyle ki 2019 yılında Almanya'nın elektrikli ve elektriksiz hatlarının toplam uzunluğu 39.068 km olup gelişmekte olan ülkeleri temsil eden Yunanistan (2.280 km), İspanya (16.006 km) ve Türkiye'den (10.378 km) oldukça fazladır. Yine çalışmada tespit edildiği üzere aynı yıl Almanya'nın elektrikli ve elektriksiz hatlarının toplam uzunluğu Avusturya (5.5615 km), Çek Cumhuriyeti (9.562 km), Estonya (1.167 km), Finlandiya (5.923 km), Macaristan (7.743 km), İrlanda (2.045 km), Letonya (1.859 km), Litvanya (1.910 km), Lüksemburg (271 km), Norveç (3.890 km), Polonya (19.359 km), Slovenya (1.209 km), İsveç (10.899 km) ve İsviçre'den (5.288 km) fazladır (https://ec.europa.eu/eurostat/databrowser/view/rail_if_line_ga/default/table?lang=en&category=rail.rail_if Erişim tarihi: 23.06.2025). Aynı zamanda 2021 yılında Almanya'nın nüfusu (81.936.440) yukarıda bahsedilen tüm ülkelerin nüfusundan fazladır (https://ec.europa.eu/eurostat/databrowser/view/cens_21agr2/default/bar?lang=en&category=cens.cens_21.cens_21dc Erişim tarihi: 23.06.2025). Dolayısı ile Almanya gibi gelişmiş bir ülkede demiryolu altyapı yatırımlarının fazla olmasının nedeninin ülkenin ekonomik yapısına ek olarak coğrafi özellikler ve nüfus yoğunluğu olduğu söylenebilir. Çünkü büyük nüfusa sahip gelişmiş ülkeler daha kapsamlı ulaşım ağlarına ihtiyaç duyarlar ve demiryolu altyapı yatırımlarına daha fazla finansman ayırırlar. Tam aksine nüfus yoğunluğu nispeten az ve ekonomik açıdan gelişmeye çalışan ülkelerin ise bu çalışmada da belirlendiği üzere demiryollarından ziyade karayollarına daha çok önem verdikleri söylenebilir. Özellikle engebeli bir coğrafyaya sahip Slovenya ve verimli arazileri ile bilinen Macaristan gibi ülkelerin demiryollarından ziyade karayollarına daha çok yatırım yaptıkları görülmektedir. Öyle ki 2019 yılında otoyol ve e-yolların uzunluğu Macaristan'da 1.723.200 km ve Slovenya'da 623.310 km iken; Almanya'da yalnızca 13.183 km'dir (https://ec.europa.eu/eurostat/databrowser/view/road_if_motorwa/default/table?lang=en&category=road.road_if Erişim tarihi: 23.06.2025).

Çalışmada ortaya çıkan önemli bulgulardan biri de kişi başına düşen demiryolu altyapı yatırımlarının en gelişmiş ülkeler ile gelişmiş ülkeler arasında farklılığa sebep olduğudur. Bu kapsamda en gelişmiş ülkeler olan ABD ve Almanya'ya kıyasla Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore ve Birleşik Krallık'tan oluşan gelişmiş ülkelerde kişi başına düşen demiryolu altyapı yatırımlarının daha yüksek olduğu belirlenmiştir. Bu sonucun ortaya çıkmasının başlıca nedeninin gelişmiş ülkelerdeki ulaşım politikaları olduğu söylenebilir. Nitekim Japonya'nın 2027 yılında faaliyete geçirmeyi planladığı Chūō Shinkansen yüksek hızlı demiryolu hattının yanı sıra Fransa'daki TGV (Train à Grande Vitesse) yüksek hızlı tren ağı bu ülkelerde özellikle demiryolları ile yolcu taşımacılığının artmasına katkı sağlayacak yatırımlardır. Zaten bu iki ülkede de 2019-2022 yılları arasındaki dönemde yolcu taşımacılığı Almanya ve Amerika'ya göre oldukça fazladır (<https://data-explorer.oecd.org/> Erişim tarihi: 23.06.2025). Yine Belçika'daki yoğun demiryolu bağlantıları ve Birleşik Krallık'taki demiryollarının modernizasyon çalışmaları düşünüldüğünde gelişmiş ülkelerin demiryolu altyapı yatırımı konusunda proaktif bir yaklaşım sergiledikleri aşikardır. ABD ve Almanya'da ise demiryollarında yolcu taşımacılığından daha çok yük taşımacılığı fazladır (<https://data-explorer.oecd.org/> Erişim tarihi: 23.06.2025). Bu durum ABD ve Almanya'da her ne kadar verimli demiryolu ağları olsa da kişi başına düşen demiryolu altyapı yatırımlarının sınırlı kalmasına sebebiyet vermektedir.

Çalışmada az gelişmiş ülkeler ile gelişmiş ve gelişmekte olan ülkeler arasında farklılığa sebep olan değişkenin ise GSYH başına düşen toplam iç ulaşım altyapı yatırımı olduğu saptanmıştır. Az gelişmiş ülkelerde GSYH başına düşen toplam iç ulaşım altyapı yatırımının gelişmiş ve gelişmekte olan ülkelere kıyasla yüksek olduğu görülmüştür. Nitekim bu sonucun şaşırtıcı olmadığı söylenebilir. Çünkü taşımacılık altyapısına yapılan yatırımlar verimlilik artışına ve böylelikle de ekonomik büyümeye neden olmaktadır (Navickas, Sujeta ve Vojtovich, 2011: 234). Az gelişmiş ülkelerde malların ve insanların verimli bir şekilde taşınması ve dolayısı ile de ekonomik büyümeyi teşvik ederek yaşam standartlarının artırılabilmesi adına GSYH'lerinin önemli bir bölümünü altyapıyı kapsayan kamu harcamalarına ayırmaya çalışırlar. Öyle ki 2019 yılında toplam iç ulaşım altyapı yatırımlarının GSYH içerisindeki payı Macaristan'da %2,2 iken Avustralya ve Norveç'te %1,5 ve İsviçre'de %1,2'dir. Gelişmiş ülkeler olan Amerika ve Almanya'da ise bu oranlar sırası ile %0,6 ve %0,8'dir (<https://data-explorer.oecd.org/> Erişim tarihi: 23.06.2025).

Çalışmada son olarak gelişmiş ve gelişmekte olan ülkeler arasında farklılığa sebep olan değişkenin uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payı olduğu belirlenmiştir. Gelişmekte olan ülkelerde gelişmiş ülkelere kıyasla uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının daha yüksek olduğu saptanmıştır. Gelişmekte olan ülkelere Yunanistan, İspanya ve Türkiye turizm açısından popüler destinasyonlardır. Bu durum ilgili ülkelerde yoğun hava trafiğine sebebiyet vermekte ve CO₂ emisyonlarının artmasına neden olmaktadır. Öyle ki 2019 yılında cari ABD doları bazında GSYH'nin bin birimi başına düşen havayolu yolcu taşımacılığı Türkiye'de 0.14, Yunanistan'da 0.07, İspanya'da 0.06 iken; gelişmiş ülkelere nazaran yüksek olması çalışmada beklenen bir sonuçtur.

2.5. Çıkarımlar

2.5.1. Teorik ve uygulama çıkarımları

Bu çalışma bir ön analiz niteliğinde veri madenciliği yöntemlerinden hiyerarşik olmayan k-ortalamlar kümeleme algoritmasının kullanılmasının ardından sınıflandırıcı yöntemlerden biri olan karar ağaçlarında J48 algoritmasının kullanılması yönü ile önceki ampirik çalışmalardan farklı olarak iki adımlı bir veri madenciliği analizine dayanmaktadır. Bu nedenle metodolojik katkılar açısından, bu çalışma ilk olarak araştırma metodolojisine yenilikçi bir yaklaşım olarak çift aşamalı bir veri madenciliği analizi sunmaktadır. Böylelikle bu çalışma kümeleme analizi sonucunda elde edilen nominal hedef değişkenlerin girdi olarak karar ağaçları ile sınıflandırma yaparken kullanılabilirliğini göstermektedir. İkinci olarak, önceki çalışmaların çoğu sanayi ve hizmet sektörlerindeki en önemli değişkenlerin ortaya çıkarılmasına odaklandıklarından bu çalışma, lojistik sektöründeki önemli değişkenlerin tespit edilmesi yönü ile literatüre katkı sağlayacaktır. Üçüncüsü, her geçen gün lojistik sektöründe hızla biriken büyük veri göz önüne alındığında ülkeler arasında farklılığa sebep olan taşımacılık göstergelerinin belirlenmesi için hala ek araştırmalara ihtiyaç duyulduğundan, bu çalışma OECD ülkeleri arasında farklılığa sebep olan taşımacılık göstergelerini belirleyerek mevcut literatüre katkı sunmaktadır. Son olarak, karar ağaçları ile yapılan sınıflandırma başarısı %76'dır.

Bu oran teorik modelin sınıflandırma başarısını ve dolayısı ile de bulguların güvenilirliğini açıkça göstermektedir.

Hem politika belirleyiciler hem de araştırmacılar bu çalışmadan büyük ölçüde faydalanacaklardır. Çünkü bu çalışma önemli uygulama çıkarımlarına sahiptir. İlk olarak mevcut çalışmanın bulguları ülkeler arasında farklılığa sebebiyet veren değişkenlerin demiryolu ve iç ulaşım altyapı yatırımları ile enerji ve çevre temelli göstergeler olduğunu ortaya koymuştur. Dolayısı ile politika belirleyiciler, OECD üyesi ülkeler için çalışma bulgularından yararlanarak doğru lojistik politikalar belirleyebilmeme imkanına sahiptirler. Nitekim çalışmada elde edilen bulgular neticesinde politika belirleyicilerin, özellikle az gelişmiş ve gelişmekte olan OECD üyesi ülkelerde demiryolu ve iç ulaşım altyapı yatırımlarını destekleyecek politikalara ağırlık vermeleri doğru olacaktır. Aynı zamanda uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarını ise sınırlayıcı tedbirleri hayata geçirmeleri faydalı olacaktır. Aynı zamanda araştırmacıların, bahsedilen destek ve tedbirlerin OECD üyesi ülkelerin ekonomik gelişme düzeyleri arasında meydana getireceği farklılıkları ve bu farklılıkların lojistik sektörüne etkisini değerlendirmeleri yararlı olacaktır.

2.6. Sonuç ve Öneriler

Günümüzde yeni bilgi işleme teknolojilerinden biri olarak nitelendirilen veri madenciliğinin özünde bir keşif sürecini ifade ettiği söylenebilir. Bu keşif sürecinin amacı ise, daha önce keşfedilmemiş bilgilerin ve ilişkilerin istatistiksel yöntemler yardımı ile açığa çıkarılmasıdır. Bu çalışmada da ülkelerin ekonomik gelişme düzeylerine göre kümeler ayrılması ve bu ülkeleri birbirinden ayıran en önemli taşımacılık göstergelerinin tespit edilmesi için veri madenciliği sürecinden yararlanılmıştır. Nitekim öncelikle 29 OECD üyesi ülkenin 2019 yılına ait GSYH, ihracat, ithalat, enflasyon oranı ve işsizlik oranı verileri ile k- ortalamalar algoritması kullanılarak bir ön analiz niteliğinde kümeleme analizi gerçekleştirilmiştir. Kümeleme analizi sonucunda ülkeler çok gelişmiş, gelişmiş, gelişmekte olan ve az gelişmiş olmak üzere 4 kümeye ayrılmıştır. Almanya ve ABD en gelişmiş ülkeler, Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore ve Birleşik Krallık gelişmiş ülkeler, Yunanistan, İspanya ve Türkiye ise gelişmekte olan ülkeler olarak belirlenmiştir. Geriye kalan 16 adet ülke (Avusturalya, Avusturya, Çek Cumhuriyeti, Estonya, Finlandiya, Macaristan, İrlanda, Letonya, Litvanya, Lüksemburg, Yeni Zelanda, Norveç, Polonya, Slovenya, İsveç, İsviçre) ise az gelişmiş ülkeler olarak

nitelendirilmiştir. Böylelikle kümeleme analizi sonucunda ülkelerin gelişmişlik düzeyini temsil eden bir nominal hedef değişken oluşturulmuştur. Analizin ikinci aşamasında karar ağaçları ile sınıflandırma yapılabilmesi için ise; kümeleme analizi sonucunda elde edilen nominal hedef değişken ve tahminleyici olarak 29 OECD üyesi ülkeye ait 20 adet taşımacılık değişkeninin 2019 yılına ait nümerik verileri kullanılmıştır. Karar ağaçlarının oluşturulmasında ise WEKA 3.8.6 yazılımında bulunan J48 algoritması tercih edilmiş ve farklı ekonomik gelişmişlik düzeylerine sahip ülkeleri birbirinden ayıran en önemli lojistik göstergeleri belirlenmiştir. 20 adet taşımacılık değişkeninin tahminleyici olarak kullanıldığı analiz sonucunda dört adet değişkenin ülkeler arasında farklılığa sebep olduğu belirlenmiştir. Bunlar: Demiryolu altyapı yatırımı, kişi başına düşen demiryolu altyapı yatırımı, GSYH başına düşen toplam iç ulaşım altyapı yatırımı ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payıdır. Nitekim karar ağacının kök boğumunu demiryolu altyapı yatırımı oluşturmuştur. Bu doğrultuda beklenildiği üzere en gelişmiş ve gelişmiş ülkelerde demiryolu altyapı yatırımının gelişmekte olan ve az gelişmiş ülkelere göre yüksek olduğu tespit edilmiştir. Bu eğilimin başlıca nedenlerinin ekonomik büyüklüğün yanı sıra nüfus yoğunluğu ve coğrafi özellikler olduğu söylenebilir.

Demiryolu altyapı yatırımının oluşturduğu bu kök boğumunun dallarından birinde kişi başına düşen demiryolu altyapı yatırımı yer almıştır. Bu kapsamda çalışmada ortaya çıkan önemli sonuçlardan ikincisi; kişi başına düşen demiryolu altyapı yatırımlarının en gelişmiş ülkeler ile gelişmiş ülkeler arasında farklılığa sebep olduğudur. Bu kapsamda Belçika, Fransa, Japonya, Kanada, İtalya, Meksika, Kore ve Birleşik Krallık'tan oluşan gelişmiş ülkelerde en gelişmiş ülkeler olan ABD ve Almanya'ya kıyasla kişi başına düşen demiryolu altyapı yatırımının daha yüksek olduğu görülmüştür. Bu sonucun ortaya çıkmasının başlıca nedeninin gelişmiş ülkelerdeki ulaşım politikaları olduğu söylenebilir. Öyle ki gelişmekte olan ülkelerde demiryolları ile yolcu taşımacılığı ön plana çıkarırken; Almanya ve ABD'de demiryolları ile yük taşımacılığı daha fazladır. Bu durumun en gelişmiş ülkelerde kişi başına düşen demiryolu altyapı yatırımlarının sınırlı kalmasına sebebiyet verdiği söylenebilir.

Kök boğumunun diğer dalında ise, GSYH başına düşen toplam iç ulaşım altyapı yatırımı değişkeni yer almıştır. Nitekim az gelişmiş ülkeler ile gelişmiş ve gelişmekte olan ülkeler arasında farklılığa sebep olan değişkeninin GSYH başına düşen toplam iç ulaşım altyapı yatırımı olduğunun tespit edilmesi çalışmada ortaya çıkan önemli

sonuçlardan bir diğeridir. Az gelişmiş ülkelerde GSYH başına düşen toplam iç ulaşım altyapı yatırımının gelişmiş ve gelişmekte olan ülkelere kıyasla yüksek olduğu görülmüştür. Özellikle Macaristan, İsviçre ve Norveç gibi ülkelerinin erişilebilirliği arttırmak adına iç ulaşım sistemlerine daha fazla yatırım yaptıkları görülmektedir. Gelişmiş ve gelişmekte olan ülkelerde ise daha çok mevcut altyapının modernizasyonuna yönelik adımlar dikkat çekicidir.

Çalışmada ortaya çıkan son önemli sonucun gelişmiş ve gelişmekte olan ülkeler arasında farklılığa sebep olan değişkenin uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payı olmasıdır. Nitekim gelişmekte olan ülkelere gelişmiş ülkelere nazaran uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının daha yüksek olduğu saptanmıştır. Dünya genelinde uluslararası seyahat talebinde yaşanan artış ve kargo taşımacılığı gibi nedenler hava trafiğinin yükselişe geçmesine ve dolayısı ile de uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının yükselmesine sebebiyet vermektedir. Gelişmekte olan ülkelere Yunanistan, İspanya ve Türkiye turizm açısından oldukça popüler destinasyonlardır. Ayrıca İspanya'nın Avrupa ve diğer kıtalar arasında bir geçiş noktası olması sebebi ile havayolu şirketleri tarafından sıklıkla tercih edildiği söylenebilir. Bu nedenle de bu ülkelere yoğun hava trafiği söz konusudur. Belçika ve Fransa gibi gelişmiş AB üyesi ülkeler ise çevresel sürdürülebilirlik kapsamında emisyonların azaltılması adına çalışmalar yaparken; Japonya ve Kanada'da da benzer şekilde sürdürülebilir yakıtların kullanımına yönelik adımlar atılmaktadır.

Analiz sonuçları açıkça göstermektedir ki; ülkelerin ekonomik gelişme düzeylerinde farklılığa sebep olan taşımacılık değişkenleri demiryolu ulaşım altyapısı, iç ulaşım altyapısına yapılan yatırım harcamaları ile enerji ve çevre temelli göstergelerdir. Nitekim ekonomik açıdan gelişmek isteyen ülkelerin öncelikle bölgesel farklılıkları dikkate alarak karayolu, denizyolu, demiryolu ve havayolu gibi ulaşım modlarının entegrasyonunu sağlayacak akıllı ulaşım sistemlerini kamu-özel iş birlikleri ile hayata geçirmeleri faydalı olacaktır. Böylelikle iç ulaşım altyapısına yapılacak yatırımlarda yaşanacak artış malların ve insanların daha hızlı ve verimli taşınmasını sağlayacak ve ekonomik büyümenin tetikleyicisi olacaktır. Aynı zamanda gelişmiş ülkeler nispeten az gelişmiş ülkelere finansman ve teknik destek sağlamak sureti ile iş birlikleri geliştirerek mevcut demiryolu ağlarının geliştirilmesine ve yeni hatların inşasına katkıda bulunabilirler. Gelişmiş ve gelişmekte olan ülkelerin ise; elektrikli tren sistemlerini

yaygınlaştırarak demiryollarının çevresel etkilerini azaltmaya yönelik modernizasyonlara önem vermeleri sürdürülebilir büyümenin sağlanması adına önemli bir adım olacaktır. Özellikle gelişme yolundaki ülkelerin sürdürülebilir büyümenin sağlanmasında demiryollarının çevresel etkilerini azaltmaya yönelik adımların yanında mutlaka uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarını azaltmaya yönelik girişimlerde de bulunmaları gerekmektedir. Nitekim bu ülkelerde sürdürülebilir yakıt kullanımının teşvik edilmesi, havaalanlarında enerji verimli sistemler geliştirilmesi ve hava trafik yönetim sistemlerinin iyileştirilmesi adına atılacak adımlar iyi bir başlangıç olacaktır. Kısacası OECD ülkelerinde ulaşım politikalarının yerel ve uluslararası düzeyde entegrasyonunu sağlamak için kapsamlı planlamalar yapılarak bu planların hayata geçirilmesi ekonomik gelişmenin sağlanması adına oldukça önemlidir.

2.7. Çalışmanın Kısıtlılıkları ve Gelecekle İlgili Yönelimler

Çalışma sonuçlarının literatüre katkı sağlayacağı ve politika belirleyicilere bir yol haritası sunacağı düşünülse de çalışmada elde edilen sonuçlara bazı kısıtlılıklar çerçevesinde ulaşıldığı unutulmamalıdır. Bu kısıtlılıkların başında analiz için yalnızca 29 OECD üyesi ülkenin seçilmiş olması gelmektedir. Öncelikle örneklem büyüklüğü artırılarak 38 OECD üyesi ülkenin hepsi analize dahil edilebilir. Ayrıca AB üyesi ülkeler için de mevcut analiz tekrarlanabilir. Bir ön analiz niteliğinde uygulanan kümeleme analizinde ülkelerin ekonomik gelişme düzeylerinin belirlenmesinin ardından karar ağaçları uygulamasında nominal değişken olarak ülkelerin ekonomik gelişme düzeylerine ek olarak OECD üyesi veya AB üyesi olup olmamasına göre bir ayırım yapılarak analiz genişletilebilir. Böylelikle OECD veya AB üyesi olup gelişme düzeyi farklılaşan ülkeleri birbirinden ayıran taşımacılık göstergeleri belirlenebilir. Bu çalışmada karar ağaçları ile sınırlandırma yapılır iken 20 adet taşımacılık değişkeni kullanılmıştır. Değişken sayısı artırılarak model yeniden kurulabilir. Nitekim yolcu taşımacılığı ve ulaşım modlarının trafik yoğunluğuna ilişkin değişkenler analize dahil edilebilir. Ayrıca mevcut analizde yalnızca 2019 yılı verileri kullanılmıştır. Bu doğrultuda 2019 yılı sonrası için mevcut analizler tekrarlanarak Covid-19 Krizi'nin taşımacılık sektörüne etkileri değerlendirilebilir. Aynı zamanda bu çalışmada sınıflandırma amacı ile karar ağacı algoritmalarından J48 algoritması kullanılmıştır. Veri madenciliği sürecinde yer alan farklı sınıflandırma yöntemleri ile analiz tekrarlanabilir ve aynı sonuçların elde edilip edilmediğine dair karşılaştırma yapılarak literatüre katkı sunulabilir.

3. BÖLÜM

YAPAY SİNİR AĞLARI İLE ÖNGÖRÜ

ÖZET

Ülkelerin ulaşım altyapı göstergelerine ait değişkenlerin ileriye yönelik öngörülerinin gerçekleştirilmesi çeşitli alanlarda ortaya çıkacak ekonomik ve sosyal etkilerin belirlenmesi açısından kritik öneme sahiptir. Bu doğrultuda çalışmanın amacı; taşımacılık göstergelerinin popüler bir yapay sinir ağı türü olan çok katmanlı ağlar kullanılarak ileriye yönelik öngörülerinin gerçekleştirilmesidir. Çalışmanın amacı doğrultusunda OECD üyesi 29 ülkenin her biri için farklı yıl aralıkları kullanılarak demiryolu altyapı yatırımı, kişi başına düşen demiryolu altyapı yatırımı, GSYH başına düşen toplam iç ulaşım altyapı yatırımı ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payı olmak üzere dört adet değişkenin yıllık verileri ile 2025 yılına kadar ileriye yönelik öngörüsü WEKA 3.8.6 yazılımında gerçekleştirilmiştir. Çok katmanlı ağlar ile oluşturulan modellerin performansları MAPE değerleri kullanılarak ölçülmüştür. Çalışmanın sonucunda çok katmanlı ağlar ile kurulan modellerin çoğunluğunun MAPE değerinin oldukça düşük olduğu, dolayısı ile de başarılı sonuçlar elde edildiği saptanmıştır. Bu kapsamda taşımacılık göstergelerinin ileriye yönelik öngörülerinin gerçekleştirilmesinde çok katmanlı algılayıcı ağların yani yapay sinir ağların kullanılabileceği belirlenmiştir. Gerçekleştirilen öngörüler neticesinde Avustralya, Avusturya, Kanada, Çek Cumhuriyeti, Estonya, Litvanya, Lüksemburg, Meksika, Norveç, Japonya, İspanya, İsveç, İsviçre ve Birleşik Krallık'ta demiryolu altyapı yatırımlarının 2025 yılında artışa geçeceği saptanmıştır. Kişi başına düşen demiryolu altyapı yatırımlarında Avustralya, Avusturya, Litvanya, Norveç ve Birleşik Krallık'ta 2025 yılında artış yaşanacağı saptanır iken; Kanada, Fransa, Finlandiya ve Türkiye'de aynı yıl düşüş yaşanacağı tespit edilmiştir. GSYH başına düşen toplam iç ulaşım altyapı yatırımlarında 2025 yılında Finlandiya, Norveç ve İsveç'te azalış yaşanacağı öngörülmüş iken, Estonya ve Türkiye'de tam tersine yükseliş yaşanacağı öngörülmüştür. Son olarak ise; Avusturya, İrlanda, Letonya, Litvanya Lüksemburg, İsviçre, Türkiye ve Birleşik Krallık'ta 2025 yılında uluslararası havacılık

sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının artacağı; Avustralya, Estonya ve Norveç'te ise azalacağı öngörülmüştür.

Anahtar Sözcükler: Yapay Sinir Ağları, Çok Katmanlı Ağlar, WEKA, OECD, Taşımacılık.



ABSTRACT

Realizing predictive estimates of variables related to transportation infrastructure indicators of countries is of critical importance in determining the economic and social impacts that will arise in various areas. The aim of this study is to make predictive estimates of transportation indicators using multilayer networks, a popular type of artificial neural network. In line with the purpose of the study, annual data and predictive estimates until 2025 of four variables, namely railway infrastructure investment, railway infrastructure investment per capita, total domestic transport infrastructure investment per GDP and the share of CO₂ emissions from international aviation shelters in total CO₂ emissions, were carried out in WEKA 3.8.6 software using different year intervals for each of the 29 OECD member countries. The performances of models created with multilayer networks were measured using MAPE values. As a result of the study, it was determined that the MAPE value of the majority of the models established with multilayer networks was quite low, and therefore successful results were obtained. In this context, it has been determined that multilayer sensor networks, namely artificial neural networks, can be used in Realizing predictive estimates of transportation indicators. As a result of the forecasts, it has been determined that railway infrastructure investments will increase in 2025 in Australia, Austria, Canada, Czech Republic, Estonia, Lithuania, Luxembourg, Mexico, Norway, Japan, Spain, Sweden, Switzerland and the United Kingdom. While per capita railway infrastructure investment is expected to increase in Australia, Austria, Lithuania, Norway and the United Kingdom in 2025, it is expected to decrease in Canada, France, Finland and Turkey in the same year. While total domestic transport infrastructure investments per unit of GDP are expected to decrease in Finland, Norway and Sweden in 2025, an increase is expected in Estonia and Turkey. Finally, it is projected that the share of CO₂ emissions from international aviation shelters in total CO₂ emissions will increase in 2025 in Austria, Ireland, Latvia, Lithuania, Luxembourg, Switzerland, Turkey and the United Kingdom, while it will decrease in Australia, Estonia and Norway.

Keywords: Artificial Neural Networks, Multilayer Networks, WEKA, OECD, Transportation.

GİRİŞ

Ülke ekonomisinin yönlendirilmesinde, etkin bir ulaşım sisteminin yeri oldukça önemlidir. Nitekim karayolu, demiryolu, havayolu ve liman gibi ulaşım içeriklerinin geliştiği ülkelerde yer değiştirme imkânında yaşanan artışın yatırım, sanayileşme, nüfus, ticaret, inşaat gibi ekonomik ve sosyal olguların da gelişmesine de aracılık yaptığı bilinmektedir (Erdoğan, 2016: 197). Fakat beklenen pozitif dışsallıkların ortaya çıkabilmesi için doğru planlanmış ve ülke çıkarını gözetten politikalar sonucunda ulaşım altyapı yatırımlarının gerçekleştirilmesi gerekmektedir. Çünkü doğru planlanmamış ulaşım altyapı yatırımları toplum ve çevre açısından negatif dışsallıkların ortaya çıkmasına sebebiyet vermektedir. Öyle ki kentsel gürültü, çevre kirliliği ve ulaşım altyapı yatırımlarının inşası sırasında su kalitesinde düşüşün ortaya çıkması negatif dışsallıklardan yalnızca bir kaçıdır (Wang et al., 2018: 2-3). Bu kapsamda ülkelerin altyapı yatırımlarının gelecekte nasıl değişeceğinin analiz edilmesi ortaya çıkabilecek pozitif ve negatif dışsallıkların tespit edilebilmesi açısından büyük önem taşımaktadır. Ulaşım altyapı yatırımlarına ilişkin yapılacak öngörüler neticesinde hem ülkelerin ulaşım sistemleri konusunda doğru politikalar üretilerek uzun vadeli yatırım planlamaları yapılabilecek hem de ortaya çıkabilecek negatif dışsallıklar azaltılabilecektir.

Ülkelerin gerçekleştirecekleri ulaşım altyapı yatırımlarının önemi göz önüne alındığında literatürde bu konuda bir eksiklik tespit edilmiştir. Nitekim özellikle literatürde OECD ülkelerine ait altyapı yatırımlarının ileriye yönelik öngörülerinin gerçekleştirildiği ve kapsamlı politika çıkarımlarının yapıldığı bir çalışmaya rastlanmamıştır. Öyle ki literatürde örneklem olarak Avrupa Birliği (AB)'ni; BRICS (Brezilya, Rusya, Hindistan, Çin ve Güney Afrika) ve MINT (Meksika, Endonezya, Nijerya ve Türkiye) ülkelerini seçen çalışmaların (Demir & Eminler, 2020; Karakurt & Aydın, 2023) yanında yalnızca Türkiye için öngörülerde bulunan çalışmalar (Şen et al., 2021; Özdemir, 2021; Kılınç et al., 2022; Ağbulut, 2022) çoğunluktadır. AB, BRICS ve MINT ülkelerini örneklem olarak seçen öngörü çalışmalarında özellikle CO₂ salınımına odaklanıldığı; Türkiye için yapılan tahminlemelerde ise denizcilik değişkenlerinin yer aldığı görülmüştür. OECD üyesi ülkeleri örneklem olarak seçen ve taşımacılık verileri ile yapay sinir ağlarını kullanarak tahminleme gerçekleştiren yalnızca bir adet çalışmaya (Islam et al., 2022) rastlanmıştır. Fakat Islam et al., (2022) çalışmalarında özellikle karayolu kazalarına odaklanmışlardır. Dolayısı ile literatürde bu çalışmada olduğu gibi OECD ülkelerinin hem altyapı yatırımlarına hem de havayolu taşımacılığının sebep

olduğu CO₂ emisyonlarının öngörüsüne odaklanan bir çalışma mevcut değildir. Literatürdeki bu mevcut boşluğu doldurmak adına bu çalışmanın amacı; 29 OECD üyesi ülkeye ait demiryolu altyapı yatırımı, kişi başına düşen demiryolu altyapı yatırımı, GSYH başına düşen toplam iç ulaşım altyapı yatırımı ile uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payı olmak üzere dört adet değişkenin yıllık verileri ileriye yönelik öngörülerinin gerçekleştirilerek 2025 projeksiyonunu ortaya koymaktır. İnsan beyninden ilham alarak geliştirilen, eksik veriler ile çalışabilme, doğrusal olmayan ilişkileri keşfedebilme ve hatalara karşı toleranslı olma gibi yetenekleri ile ön plana çıkan yapay sinir ağlarının (YSA) günümüzde pek çok farklı problemin çözümünde sıklıkla kullanılmakta ve literatürdeki çalışmalarda da (Gosasang et al., 2011; Şen et al., 2021; Özdemir, 2021; Islam et al., 2022; Mutascu, 2022) geleneksel sistemlere göre gerçeğe daha yakın sonuçlar ürettiği vurgulanmaktadır. Bu doğrultuda bu çalışmada ülkelerin ulaşım altyapı yatırımlarına yönelik tahmin ve öngörülerin gerçekleştirilmesinde üstün özellikleri nedeni ile popüler bir YSA türü olan çok katmanlı algılayıcılar (ÇKA) tercih edilmiştir. Çünkü ÇKA, girdi ve çıktı katmanları arasında bulunan en az bir gizli katman sayesinde doğrusal olmayan ilişkileri kolaylıkla algılayabilmekte ve daha doğru sonuçlar üretebilmektedir. Analizler WEKA 3.8.6 yazılımında gerçekleştirilmiştir. Çalışmada öncelikle model performanslarının ölçümü yapılmıştır. Çok katmanlı ağlar ile oluşturulan modellerin performansları MAPE değeri kullanılarak ölçülmüş ve kurulan modellerin çoğunluğunun MAPE değerinin oldukça düşük olduğu, dolayısı ile de daha literatürdeki sonuçlarla benzer şekilde başarılı sonuçlar elde edildiği saptanmıştır. Çalışmanın sonucunda elde edilen ikinci bulgu; OECD ülkelerinden Avustralya, Avusturya, Belçika, Kanada, Çek Cumhuriyeti, Estonya, Litvanya, Lüksemburg, Meksika, Norveç, Japonya, İspanya, İsveç, İsviçre, Türkiye ve Birleşik Krallık'ta demiryolu altyapı yatırımlarının 2019-2023 döneminde belirli yıllarda azalış gösterdiği, Ancak Belçika ve Türkiye dışında bahsedilen diğer ülkelerde demiryolu altyapı yatırımlarının 2025 yılında artışa geçeceği öngörülmüştür. Üçüncü olarak; kişi başına düşen demiryolu altyapı yatırımlarında Avustralya, Avusturya, Litvanya, Norveç ve Birleşik Krallık'ta 2025 yılında artış yaşanacağı öngörülür iken; Kanada ve Finlandiya, Fransa ve Türkiye'de aynı yıl düşüş yaşanacağı tespit edilmiştir. Dördüncü olarak; İsveç'te 2022 yılı, Finlandiya'da ise 2023 yılı sonrasında GSYH başına düşen toplam iç ulaşım altyapı yatırımlarında sürekli azalış yaşanacağı öngörülür iken, Norveç'te 2023 ve 2025 yıllarında keskin düşüşler olacağı öngörülmüştür. Türkiye'de 2022 yılındaki, Estonya'da ise 2022 ve 2024 yıllarında yaşanan azalışlar sonrasında

GSYH başına düşen toplam iç ulaşım altyapı yatırımlarında 2025 yılında yükseliş yaşanacağı öngörülmüştür. Son olarak ise; 2025 yılında Avusturya, İrlanda, İtalya, Letonya, Litvanya, Lüksemburg, İsviçre, Türkiye ve Birleşik Krallık'ta uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının artacağı; Avustralya, Estonya ve Norveç'te ise azalacağı öngörülmüştür.

3.1. Literatür Taraması

Literatürde yapay sinir ağları kullanılarak tahmin ve öngörü yapılan bazı çalışmalar Tablo 3.1.'de gösterilmiştir. Tablo 3.1. incelendiğinde ise; tahmin ve öngörü yapılan çalışmalarda yapay sinir ağlarının yanında bazı geleneksel yöntemlerin de tercih edildiği saptanmıştır. Bu geleneksel yöntemler şunlardır: Lineer regresyon, Box Jenkins, Destek Vektör Makineleri ve Vektör Otoregresyon (VAR). Literatürde yapay sinir ağları ve geleneksel yöntemler kullanılarak tahmin ve öngörü yapılan çalışma sonuçlarında ise yapay sinir ağlarının daha güçlü sonuçlar ürettiği vurgulanmıştır.

Tablo 3.1. Yapay Sinir Ağları v Kullanarak Yapılan Çalışmalar

Yazar-Yıl	Çalışmanın Başlığı	Veriler	Yöntem	Bulgular
(Gosasang et al., 2011).	A Comparison of Traditional and Neural Networks Forecasting Techniques for Container Throughput at Bangkok Port.	Konteynır sayısı, ihracat, ithalat, GSYH, dünya GSYH'SI, döviz kuru, nüfus, enflasyon, faiz oranı, yakıt fiyatı verileri kullanılmıştır. Veriler 1999-2010 yılları arasında kapsamaktadır.	Lineer regresyon ve yapay sinir ağları.	Yapay sinir ağlarının performansının geleneksel sistemlere göre daha iyi olduğunu saptanmıştır.
(Demir & Eminler, 2020).	Estimation of CO ₂ Emissions From Air Transportation In EU Countries By Artificial Neural Networks.	AB ülkeleri ve aday ülkelerin CO ₂ emisyonlarının tahmini için 2006-2015 yıllarına ait CO ₂ emisyonları, uçuş tipi, filo yaşı, uçuş ve yolcu sayıları kullanılmıştır.	Yapay sinir ağları.	Çalışma sonuçları hava taşımacılığından kaynaklanan CO ₂ emisyonlarının tahmininde yapay sinir ağlarının kullanılabileceğini göstermiştir.
(Şen et al., 2021).	Türkiye'de Limanlarda Yük Taşımacılığı Veri Analizi.	Türkiye'de denizcilik istatistiklerine ait 2004-2019 yılları arasındaki veriler	Lineer regresyon ve yapay sinir ağları.	Yapay sinir ağlarının gerçeğe daha yakın sonuçlar ürettiği tespit edilmiştir.

		kullanılmıştır. Bunlar: İhracat Türk bayraklı, ihracat kendi bayraklı, ihracat diğer ülke bayraklı.		
(Jena et al., 2021).	Forecasting the CO ₂ Emissions at the Global Level: A Multilayer Artificial Neural Network Modelling.	Emisyon salınımı yapan 17 ülkenin 1960-2016 yıllarına ait verileri kullanılmış ve 2017, 2018 ve 2019 yıllarına ilişkin tahminler gerçekleştirilmiştir.	Yapay sinir ağları.	Tahmin doğruluğu %96 olarak gerçekleşmiştir. Sonuçlar; Çin, Hindistan, İran Suudi Arabistan ve Endonezya'nın yakın gelecekte karbon salınımını arttıracaklarını bunun yanında Türkiye, Brezilya, Güney Kore ve Güney Afrika'nın yüksek emisyonlu bir büyüme göstereceğini ortaya çıkarmıştır. Öte yandan ABD, İngiltere, Fransa, Japonya, İtalya, Kanada ve Avustralya'nın emisyonlarını sürekli azaltacağı ortaya çıkmıştır.
(Özdemir, 2021).	Model Proposal for Future Estimates in Maritime Industry: The Case of Container Handling in Turkish Ports.	Türkiye'ye ait 2005-2018 yılları arasındaki aylık konteynır elleçleme verileri kullanılmıştır.	Yapay sinir ağları ve Box-Jenkins.	2022 yılına ilişkin tahminler gerçekleştirilmiştir. Yapay sinir ağlarının daha yüksek tahmin doğruluğu sağladığı belirlenmiştir.
(Kılınç et al., 2022).	Türkiye Limanlarındaki Konteyner ve Yük Elleçleme Hacimlerinin YSA Narx Modeli İle Öngörülmesi.	Türkiye'nin 2004-2020 dönemine ait aylık veriler kullanılmıştır. Konteynır elleçleme ve yük elleçleme miktarı, GSYH, Döviz Sepeti Kuru, Tüketici Güven Endeksi, Brent Petrol, Sanayi Üretim Endeksi, ihracat ve ithalat rakamları analize tabi tutulmuştur.	Yapay sinir ağları.	18 aylık öngörü değerleri hesaplanmıştır. Öngörü değerlerinden açıklanan 4 ay ile tahminlerin ve gerçek değerlerin karşılaştırması yapılmıştır.

(Ağbulut, 2022).	Forecasting of Transportation-Related Energy Demand And CO ₂ Emissions In Turkey With Different Machine Learning Algorithms.	Türkiye için yapılan tahminde 1960-2016 yıllarına ait GSYH, nüfus, araç kilometresi ve yıl değişkenleri kullanılmıştır.	Yapay sinir ağları ve destek vektör makineleri.	Türkiye’de 2050 yılına kadar enerji talebi ve ulaşımdan kaynaklı CO ₂ emisyonlarında bugüne kıyasla 3,4 katlık bir artış yaşanacağı tespit edilmiştir.
(Islam et al., 2022).	Road Infrastructure Investment Limits Based on Minimal Accidents Using Artificial Neural Network.	36’dana fazla OECD üyesi ve ortak ülkenin 1994-2016 dönemine ait yıllık verileri kullanılmıştır.	Yapay sinir ağları ve regresyon analizi.	Yapay sinir ağlarının regresyon modelinden çok daha iyi sonuçlar ürettiği belirtilmiştir.
(Mutascu, 2022).	CO ₂ Emissions In The USA: New Insights Based on ANN Approach.	ABD’deki CO ₂ emisyon tahmini için 1984:01-2020:04 dönemi verileri kullanılmıştır.	Yapay sinir ağları ve vektör otoregresyon (VAR).	Yapay sinir ağlarının daha güçlü sonuçlar ürettiği saptanmıştır.
(Gatarić et al., 2023).	Predicting Road Traffic Accidents—Artificial Neural Network Approach.	Sırbistan ve Bosna Hersek’e ait yol uzunluğu, yıllık ortalama günlük trafik hacmi, arazi tipi, eğrilik, şerit genişliği ve hız limiti verileri kullanılmıştır.	Yapay sinir ağları.	Trafik kazalarının tahmininde yapay sinir ağlarının kullanımının uygun olduğu vurgulanmıştır.
(Karakurt & Aydın, 2023).	Development of Regression Models to Forecast The CO ₂ Emissions From Fossil Fuels In The BRICS And MINT Countries.	BRICS ve MINT ülkelerindeki fosil yakıt kaynaklı karbondioksit emisyonları 2025’ten 2045’e kadar olan dönem için beşer yıllık periyotlarla tahmin edilmiştir.	Regresyon analizi.	BRICS ve MINT ülkelerindeki fosil yakıt kaynaklı karbondioksit emisyonlarının gelecekte artacağı saptanmıştır.


3.2. Araştırma Metodolojisi ve Veri Seti

3.2.1. Yapay sinir ağlarının tanımı ve özellikleri


Yapay sinir ağları (YSA) sınıflandırıcı yöntemler içerisinde yer almaktadır ve ilham kaynağı insan beynidir. Öyle ki yapay sinir ağları ile ilgili çalışmaların odağında insan beyninin doğrusal olmayan, karmaşık ve paralel bir bilgisayar olduğu düşüncesi yer

almakta ayrıca insan beyninin geleneksel bilgisayarlardan farklı hesaplamalar yapabildiği kanısı bulunmaktadır (Haykin, 2009: 1). Bu kapsamda Haykin (2009: 2) yapay sinir ağlarının insan beynine benzediğini belirtmiş ve yapay sinir ağlarının tanımını şu şekilde yapmıştır: “Yapay sinir ağları; birbirine paralel ve dağıtılmış düzende çalışan, doğal eğilime sahip basit işlem birimlerinden oluşan bir işlemcidir”. Tanımdan da anlaşılacağı üzere aslında yapay sinir ağları, biyolojik bir temele dayanmaktadır (Cemaloğlu & Duykuluoğlu, 2020: 499-504). Yapay sinir ağları, hayvan beynindeki karmaşık öğrenme sistemlerinin birbiri ile bağlantılı nöron kümelerinden oluşmasını ilham almaktadır (Larose & Larose, 2014: 187). Yapay sinir ağları, ağırlıklandırılmış olarak birbirine bağlanan çok sayıda nörondan meydana gelmekte ve biyolojik sinir sistemini taklit etmektedir (Yurtoğlu, 2005) Basit işlem nöronları ile birbirine bağlanan yapay sinir ağları insan beynini ve sinir sistemini taklit eden bir yapıdadır (Sing & Mishra, 2015: 86). Kısacası yapay sinir ağları insan beynini ve sinir sistemini taklit eden bir girişimi ifade etmektedir.

İnsan beynini ve sinir sistemini taklit eden yapay sinir ağı ile gerçek bir sinir sisteminde birbirine benzer elemanlar bulunduğu söylenebilir. Şekil 3.1.’de gerçek bir sinir hücresinin bileşenleri, Şekil 3.2.’de ise yapay bir sinir hücresinin bileşenleri gösterilmiştir. Gerçek bir sinir sisteminin bileşenlerini sinaps, dentrit, hücre gövdesi ve aksonlar oluşturur iken yapay bir sinir ağının bileşenlerini ise ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve eleman çıkışı oluşturmaktadır. Gerçek bir sinir sisteminde yer alan sinaps, dentrit, hücre gövdesi ve aksonlar yapay bir sinir ağında sırası ile ağırlıklar, toplama fonksiyonu, transfer fonksiyonu ve eleman çıkışını ifade etmektedir (Kubat, 2015: 669).




Şekil 3.1. Gerçek Bir Sinir Hücresinin Bileşenleri (Mijwel, 2017:1).



Şekil 3.2. Yapay Bir Sinir Hücresinin Bileşenleri (Mijwel, 2017: 1).

Yapay sinir ağının genel yapısı Şekil 3.3.'de gösterilmiştir. Bir yapay sinir ağının genel yapısı incelendiğinde, birbiri ile bağlantılı sinirlerin yer aldığı üç bölümden oluştuğu görülmektedir: Girdi katmanı, gizli katman ve çıkış katmanı. Giriş katmanında girdileri dışarıdan alan nöronlar bulunmaktadır. Dışarıdan alınan girdiler giriş katmanından geçerek gizli katmana iletilirler. Ağ içerisindeki diğer nöronlar ile bağlantılı çok sayıda nörondan oluşan gizli katmanda ise bilgiler işlenerek çıktı katmanına iletir. En uçta yer alan çıktı katmanı ise, gizli katmandan gelen bilgileri işleyerek var olan problem için bir çıktı üretmektedir (Ersöz, 2019: 69-70).



Şekil 3.3. Yapay Sinir Ağının Genel Yapısı (Bramer, 2020: 7).


İnsan beynini taklit eden yapısı, yapay sinir ağlarının güçlü bir teknik olmasına neden olmaktadır (Ersöz, 2019: 68-69; Takçı, 2020: 127-128). Ayrıca yapay sinir ağlarının sahip olduğu karakteristik özellikler araştırmacılara çeşitli avantajlar da sunmaktadır. Yapay sinir ağlarının araştırmacılara avantaj sağlayan karakteristik özellikleri şunlardır:

- Güçlü bir teknik olan yapay sinir ağları, basit yapısına rağmen sınıflandırma ve örüntü tanıma gibi işlevleri kolayca yerine getirebilmektedir (Larose & Larose, 2014: 187).
- Yapay sinir ağları parametreler arasındaki doğrusal olmayan ilişkileri keşfedebilmekte ve bu sayede yüksek tahmin doğruluğu sağlamaktadır (Ramageri, 2010: 303; (Hamzaçebi, 2011: 17; Ersöz, 2019: 68-69).
- Yapay sinir ağları makine öğrenmesi gerçekleştirerek benzer olaylara benzer cevaplar verebilmektedir (Öztemel, 2006: 31).
- Yapay sinir ağları örnekler yardımı ile öğrenme işlemini gerçekleştirebilir ve genelleme yapabilir (Yurtoğlu, 2005: 35-36; Öztemel, 2006: 31-32; Sönmez Çakır, 2020: 3).
- Eksik bilgileri bulabilen yapay sinir ağları bu sayede örüntü tamamlama işlemi gerçekleştirebilir (Öztemel, 2006: 329).
- Yapay sinir ağları eksik bilgiler ile de çalışabilmektedir (Öztemel, 2006: 33).
- Yapay sinir ağlarının hata toleransı geleneksel sistemlere göre daha fazladır (Öztemel, 2006: 33; Hamzaçebi, 2011: 18; Han et al., 2012: 398).
- Yapay sinir ağları, sınırsız sayıda değişken ve parametre ile çalışabilen güçlü bir tekniktir (Yurtoğlu, 2005: 36).

Yukarıda bahsedilen özellikleri yapay sinir ağlarının, farklı problemlerin çözümünde geleneksel sistemlerin aksine araştırmacılar tarafından sıklıkla tercih edilmesine yol açmaktadır. Özellikle genelleme yapabilme ve örüntü tamamlama işlevlerine yerine getirebilmesi, eksik bilgi ile çalışabilmesi, doğrusal olmayan ilişkileri açığa çıkarabilmesi ve hata toleransının yüksek olması yapay sinir ağlarını geleneksel sistemlerden farklılaştırmaktadır. Bu kapsamda yapay sinir ağları günümüzde kümeleme, sınıflandırma (Öztemel, 2006: 32, Ersöz, 2019: 68; Takçı, 2020: 127-128; Bramer, 2020: 427), öngörü (Yurtoğlu, 2005: 36) ve tahmin (Yurtoğlu, 2005: 36; Han et al., 2012: 398; Ersöz, 2019: 68; Takçı, 2020: 127-128; Bramer, 2020: 427) gibi veri madenciliği problemleri başta olmak üzere farklı alanlarda karşılaşılan problemlerin çözümü için sıklıkla tercih edilmektedir.

Günümüzde farklı alanlarda karşılaşılan problemlerin çözümünde kullanılan en popüler yapay sinir ağı türü ise çok katmanlı ağlardır. Çünkü çok katmanlı algılayıcılar, giriş ve çıkış katmanları arasında en az bir gizli katman kullanan ileri beslemeli ağlardır. Şekil 3. 4.'de bir giriş katmanı, iki gizli katman ile bir çıkış katmanından oluşan çok

katmanlı algılayıcı ağı görülmektedir. Giriş ve çıkış katmanları arasında bulunan bu gizli katmanlar, değişkenler arasındaki doğrusal olmayan ilişkileri algılayabilirler. Bu nedenle de tek katmanlı algılayıcıların aksine doğrusal olmayan problemlerin çözümünde oldukça başarılı performans sergileyebilmektedirler (Lippmann, 1988: 18).



Şekil 3.4. Çok Katmanlı Algılayıcı (Kayakuş & Terzioğlu, 2021: 98).

3.2.2. Veri seti ve veri dönüşümü

Çalışmada analizlerin gerçekleştirilebilmesi için 29 OECD üyesi ülkeye ait 4 adet taşımacılık değişkeninin verileri <https://stats.oecd.org/> web sitesinden 10 Mayıs 2024 tarihinde elde edilmiştir. Seçilen 4 adet taşımacılık değişkeninin yıl aralıkları ülkelere göre farklılık göstermektedir. Bu nedenle her ülke için farklı yıl aralıkları kullanılarak analizler gerçekleştirilmiştir. Buna göre seçilen OECD üyesi 29 ülke ve analiz için seçilen yıl aralıkları Tablo 3.2.'de, seçilen taşımacılık değişkenleri ise Tablo 3.3.'de görülmektedir.

Tablo 3.2. Öngörü Modeli İçin Seçilen OECD Üyesi Ülkeler ve Seçilen Yıl Aralıkları

Ülkeler	Yıllar	Ülkeler	Yıllar
Avusturalya	1995-2020	İtalya	1995-2019
Avusturya	1995-2020	Japonya	1995-2018
Belçika	1995-2020	Kore	2001-2018
Kanada	1995-2018	Letonya	1995-2020
Çek Cumhuriyeti	1995-2020	Litvanya	1995-2020
Estonya	1995-2020	Lüksemburg	1995-2019
Finlandiya	1995-2020	Meksika	1995-2020
Almanya	1995-2020	Norveç	1995-2019
Yunanistan	2000-2020	Polonya	1998-2020
Macaristan	1995-2020	Slovenya	2000-2020
İrlanda	1995-2018	İspanya	1995-2020

İsveç	1995-2020	İsviçre	1995-2019
Türkiye	1995-2020	Birleşik Krallık	1995-2018
Amerika	2008-2020		

Tablo 3.3. Öngörü Modeli İçin Seçilen Değişkenler

Kategori	Alt Kategori	Değişken Adı	Kod	Birim
Ulaşım Altyapısı	Yatırım Harcamaları	Demiryolu Altyapı Yatırımı	YH3	Euro
Performans Göstergeleri	Ulaşım Altyapısı	Kişi Başına Düşen Demiryolu Altyapı Yatırımı	UA4	Sabit Dolar
		GSYH Başına Düşen Toplam İç Ulaşım Altyapı Yatırımı	UA8	-
	Enerji ve Çevre	Uluslararası Havacılık Sığınaklarından Kaynaklanan CO ₂ Emisyonlarının Toplam CO ₂ Emisyonları İçerisindeki Payı	EC3	-

4 adet taşımacılık değişkeninin her bir ülkeye ait verileri <https://stats.oecd.org> web sitesinden elde edildikten sonra veriler normalizasyon işlemine tabi tutulmuştur. Çünkü yapay sinir ağları ile tahmin ve öngörü yapılacak çalışmalarda ağın giriş ve çıkışlarına belirli ön işlemlerin uygulanması yapay sinir ağına sunulan verilerin eğitiminin verimli hale gelmesine neden olur. Aynı zamanda da çok katmanlı ağlarda girdi ve çıktıların normalizasyon işlemine tabi tutulması ağın performansını yakından etkilemektedir (Yavuz & Deveci, 2012: 175). Bu nedenle çalışmada yapay sinir ağlarında gerçeğe en yakın sonucu veren Yavuz & Deveci (2012: 177) D_min_max yöntemi uygulanmıştır. Buna göre verilerin [0,1-0,9] değerleri arasına indirgenebilmesi için Eşitlik 3.1'den yararlanılmıştır:

$$x' = 0.8 * \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0.1 \quad (3.1)$$

Eşitlik 3.1'de;

x' = Normalize edilmiş veri,

x_i = Girdi değeri,

x_{min} = Girdi seti içindeki en küçük değer,

x_{max} = Girdi seti içindeki en büyük değerdir.

3.3. Uygulama ve Bulgular

Bu çalışmanın amacı; 29 OECD üyesi ülkeye ait 4 adet taşımacılık değişkenine ilişkin değerlerin 2025 yılına kadar olan süreç için ileriye yönelik öngörülerinin gerçekleştirilmesi için model oluşturulmasıdır. Bu amaç doğrultusunda analizler popüler bir yapay sinir ağı türü olan ÇKA kullanarak WEKA 3.8.6 yazılımında gerçekleştirilmiştir.

WEKA açık kaynak kodlu ücretsiz bir yazılımdır. WEKA yazılımının 3.7.4 sürümünden itibaren tahmin modelleri oluşturulmasına ve görselleştirilmesine imkân tanıyan özel bir zaman serisi analiz paketi mevcuttur (Bouckaert et al., 2013) Ülkelere ait normalize edilmiş veriler Arff formatında WEKA'daki bu zaman serisi analiz paketine aktarıldıktan sonra öncelikle verilere ait bilgiler seçilmiştir. Bu kapsamda analizi gerçekleştirilecek değişkenlerin seçimi, verilerin yıllık bazda olduğu ve %95 güven aralığında analizlerin yapılacağına ilişkin bilgiler programa kaydedilmiştir. WEKA' da ileriye yönelik öngörü modelleri oluşturulurken gecikme uzunluğu mevcut zaman serisinin periyodik (saat, gün, hafta, ay) özelliğine göre sistem veya kullanıcı tarafından en küçük ve en büyük değerlerin atanmasıyla belirlenebilmektedir. Bu doğrultuda gecikme uzunluğu, yıllık bazda olan verilerimiz için sistem tarafından en küçük 1 ve en büyük 5 olmak üzere belirlenmiştir.

Öngörü modellerinde yapay sinir ağlarının olaylar arasındaki ilişkileri belirleyebilmesi için ağıncı öncelikle eğitime tabi tutulması ve ardından performansının test edilmesi gerekmektedir. Bunun için olaylar ile ilgili örnekleri temsil eden eğitim seti araştırmacı tarafından ağa gösterilmeli ve son aşamada ağın performansı test veri seti kullanılarak belirlenmelidir (Öztemel, 2006: 31-32). Bu doğrultuda bu çalışmada ÇKA kullanarak yapılan analizlerin hepsinde tüm ülkelere ait veriler yapılan denemeler sonucunda en iyi performansı gösteren eğitim ve test veri kümelerine ayrılarak modeller oluşturulmuştur. Modellerin öngörü performansı ise test veri kümesinin ölçümü ile belirlenmiştir. Ülkeler için ayrı ayrı oluşturulan modellerin eğitim ve test veri kümeleri Tablo 3.4.'de gösterilmiştir:

Tablo 3.4. Öngörü Modeline Ait Eğitim ve Test Veri Kümeleri

Ülkeler	Çok Katmanlı Ağlar	
	Eğitim Veri Kümesi (%)	Test Veri Kümesi (%)
Avustralya	40	60
Avusturya	25	75
Belçika	50	50
Kanada	30	70
Çek Cumhuriyeti	30	70
Estonya	45	55
Finlandiya	45	55
Fransa	20	80
Almanya	30	70
Yunanistan	35	65
Macaristan	45	55
İrlanda	45	55
İtalya	50	50
Japonya	35	65
Kore	35	65
Letonya	30	70
Litvanya	45	55
Lüksemburg	45	55
Meksika	20	80
Yeni Zelanda	30	70
Norveç	25	75
Polonya	25	75
Slovenya	30	70
İspanya	20	80
İsveç	30	70
İsviçre	20	80
Türkiye	20	80
Birleşik Krallık	50	50
Amerika	15	75

ÇKA kullanarak kurulan modellerin öngörü performansı çeşitli kriterler dikkate alınarak ölçülmüştür. Modellerin öngörü performansını ölçmek için ise test veri kümesine ilişkin; hata kareleri ortalaması (Mean Squared Error – MSE), ortalama hata karelerinin karekökü (Root Mean Squared Error –RMSE), ortalama mutlak hata (Mean Absolute Error –MAE) ve ortalama mutlak yüzde hata (Mean Absolute Percentage Error – MAPE)

kriterleri kullanılmıştır. Yapay sinir ağlarında performansın ölçümü için MSE, RMSE, MAE ve MAPE değerleri aşağıda verilen denklemler yardımı ile hesaplanmıştır:

$$MSE = \frac{\sum_{i=1}^N (A_i - P_i)^2}{N} \quad (3.2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (A_i - P_i)^2}{N}} \quad (3.3)$$

$$MAE = \frac{\sum_{i=1}^N |A_i - P_i|}{N} \quad (3.4)$$

$$MAPE = \frac{\sum_{i=1}^N \frac{|A_i - P_i|}{A_i}}{N} * 100 \quad (3.5)$$

Denklemlerde;

A_i = Gözlenen değer,

P_i = Tahmin edilen değer,

$\bar{A}_i$ =Gözlenen değerlerin ortalaması,

N = Gözlem sayısıdır.

Eğitim ve test veri kümelerinin MSE, RMSE, MAE ve MAPE değerlerinin düşük olduğu modeller üstün kabul edilmektedir. Bu doğrultuda bu çalışmada her ülkenin eğitim veri kümesinin MSE, RMSE, MAE ve MAPE değerleri oldukça düşük değer almış ve eğitimler başarılı bir şekilde gerçekleşmiştir. Öngörü performansının değerlendirilmesinde ise özellikle MAPE değeri dikkate alınmıştır. Çünkü tahmin hatalarını yüzde olarak ifade eden MAPE değerinin tek başına bir anlamı bulunmaktadır. Bu sebeple de literatürde MAPE kriterinin diğer kriterlere kıyasla üstün olduğu kabul edilmektedir (Akgül, 2003: 138). Lewis (1982) MAPE değeri %10'un altında olan modelleri "çok iyi", %10 ile %20 aralığında yer alan modelleri "iyi", %20 ile %50 aralığında yer alan modelleri "kabul edilebilir" ve %50'nin üzerinde olan modelleri "yanlış ve hatalı" olarak sınıflandırmıştır.

ÇKA ile 2025 yılına kadar kurulan öngörü modellerine ait MAPE değerleri Tablo 3.5.'de gösterilmiştir. Ayrıca ÇKA ile kurulan modellerde ilk olarak ülkelerin analiz için seçilen yıl aralıklarının bir adım ilerisi öngörülmüştür. Öngörü değerleri ile gerçek değerlerin karşılaştırılması Tablo 3.6.'da yer almaktadır.

Tablo 3.5. Çok Katmanlı Ağlarla Kurulan Modellerde Test Veri Kümelerine İlişkin MAPE Değerleri

Ülke	Kod	Çok Katmanlı Ağlar						
		Adım Sayısı						
		1	2	3	4	5	6	7
Avustralya	YH3	28.55	22.24	18.22	17.89	27.96		
	UA4	39.46	41.53	45.14	52.20	61.17		
	UA8	31.56	29.78	19.75	22.11	23.20		
	EC3	38.36	40.72	42.46	42.74	43.04		
Avusturya	YH3	20.63	20.96	16.95	12.83	8.80		
	UA4	32.26	37.27	31.08	20.08	5.04		
	UA8	48.35	55.20	63.82	71.22	96.08		
	EC3	99.83	106.76	146.37	190.46	282.79		
Belçika	YH3	41.55	34.32	35.34	30.94	30.11		
	UA4	104.18	98.77	86.57	70.55	90.24		
	UA8	60.19	53.06	58.85	56.18	45.08		
	EC3	31.63	34.79	32.68	25.89	18.63		
Kanada	YH3	30.15	27.85	28.80	30.98	27.82	8.11	17.17
	UA4	38.89	56.29	32.47	33.26	43.26	28.19	54.09
	UA8	288.87	297.54	322.71	241.23	199.20	218.66	238.37
	EC3	51.67	57.76	54.11	95.99	96.95	89.88	68.28
Çek Cumhuriyeti	YH3	36.50	41.25	54.92	34.34	12.92		
	UA4	76.63	60.65	89.15	40.17	25.97		
	UA8	249.65	284.63	176.76	170.74	103.16		
	EC3	42.50	48.70	55.90	64.38	71.68		
Estonya	YH3	34.57	39.54	30.65	27.96	23.27		
	UA4	50.30	46.54	52.33	58.87	57.79		
	UA8	27.62	31.47	33.48	34.61	43.79		
	EC3	50.40	44.00	36.20	43.73	57.59		
Finlandiya	YH3	53.97	58.75	59.98	58.39	62.15		
	UA4	43.86	48.07	33.21	27.00	28.76		
	UA8	21.60	17.26	13.77	16.20	9.39		
	EC3	53.58	59.84	55.26	53.46	50.57		
Fransa	YH3	13.95	18.75	31.65	37.17	67.81		
	UA4	37.67	45.21	58.06	62.80	65.80		
	UA8	52.77	50.28	29.64	36.19	4.94		
	EC3	197.17	241.60	297.63	448.50	882.70		
Almanya	YH3	23.50	37.51	56.65	65.13	65.61		
	UA4	25.02	39.34	61.72	71.94	66.14		
	UA8	35.63	41.04	45.52	71.30	57.14		
	EC3	33.42	39.29	46.41	52.68	60.43		
Yunanistan	YH3	762.67	159.62	41.46	139.62	87.92		
	UA4	851.68	206.32	28.96	118.36	75.17		
	UA8	326.00	104.34	102.75	27.57	147.01		
	EC3	82.68	75.67	75.07	95.98	108.20		
Macaristan	YH3	47.30	48.66	69.55	54.79	55.06		
	UA4	51.65	49.53	66.01	48.66	59.28		
	UA8	93.36	92.04	118.56	134.14	52.38		
	EC3	60.71	60.93	68.55	70.35	83.24		
İrlanda	YH3	87.52	91.48	79.65	91.48	87.31	78.61	96.76
	UA4	119.11	113.02	93.33	112.63	108.85	73.16	111.86
	UA8	265.13	371.36	360.28	406.48	442.62	526.80	615.32
	EC3	36.18	37.98	28.77	38.68	39.95	21.02	9.39
İtalya	YH3	214.53	235.85	249.70	234.11	139.99	180.59	
	UA4	301.28	350.58	472.03	524.18	242.83	327.10	
	UA8	214.48	363.25	513.67	503.04	384.28	340.18	
	EC3	41.09	46.60	46.95	47.19	44.18	32.90	

Japonya	YH3	37.53	60.95	67.56	79.02	84.56	85.09	78.34
	UA4	58.64	69.19	68.04	72.96	75.16	60.28	55.20
	UA8	99.27	155.10	155.52	152.71	139.53	91.62	68.38
	EC3	58.72	60.23	58.25	51.76	44.82	59.39	89.34
Kore	YH3	31.26	29.28	39.03	23.14	25.85	8.11	N/A
	UA4	47.04	55.20	63.40	63.72	87.20	140.80	N/A
	UA8	66.05	77.17	92.91	79.02	115.94	286.88	N/A
	EC3	15.58	18.16	19.01	17.34	9.10	5.80	N/A
Letonya	YH3	137.55	131.01	153.50	174.49	193.11		
	UA4	130.44	143.83	184.04	212.91	181.88		
	UA8	51.71	51.97	48.91	56.23	60.21		
	EC3	29.27	28.55	32.80	41.78	38.48		
Litvanya	YH3	36.73	36.78	35.40	35.16	37.27		
	UA4	38.98	61.20	83.70	57.67	51.81		
	UA8	103.96	117.42	103.67	146.67	172.09		
	EC3	35.86	30.50	29.07	29.01	29.23		
Lüksemburg	YH3	34.91	34.34	37.18	29.50	19.35	12.86	
	UA4	83.54	93.63	78.60	71.50	65.46	40.40	
	UA8	127.96	112.21	110.28	140.20	167.69	222.08	
	EC3	33.77	38.55	38.42	32.21	27.39	40.05	
Meksika	YH3	37.20	41.70	44.89	34.59	17.62		
	UA4	44.26	43.02	19.71	117.99	180.79		
	UA8	158.44	237.17	260.36	392.98	514.70		
	EC3	57.98	73.16	66.65	52	9.90		
Yeni Zelanda	YH3	61.67	74.36	183.86	46.82	N/A		
	UA4	194.72	180.07	331.70	87.98	N/A		
	UA8	238.59	144.94	116.02	135.34	N/A		
	EC3	144.57	237.42	355.65	591.34	N/A		
Norveç	YH3	16.78	16.65	18.86	20.73	28.56	36.08	
	UA4	21.91	23.84	23.46	26.65	20.82	10.46	
	UA8	24.25	25.77	23.09	15.93	11.60	7.48	
	EC3	13.71	17.90	21.50	31.09	36.66	22.43	
Polonya	YH3	70.84	89.29	32.95	30.82	2.33		
	UA4	72.63	88.30	37.27	55.93	30.87		
	UA8	168.88	221.25	223.96	153.08	164.08		
	EC3	51.65	49.16	53.14	56.18	71.92		
Slovenya	YH3	88.26	111.47	70.20	37.69	18.39		
	UA4	88.98	112.07	68.02	34.09	15.14		
	UA8	60.74	70.79	60.03	102.05	101.22		
	EC3	91.70	102.88	151.65	204.93	391.48		
İspanya	YH3	50.59	48.44	5.42	11.70	23.22		
	UA4	54.82	74.23	137.07	169.31	205.89		
	UA8	34.10	82.71	40.27	95.56	88.28		
	EC3	93.66	141.01	160.74	181.41	381.37		
İsveç	YH3	24.30	29.70	24.75	56.39	74.40		
	UA4	55.43	83.26	88.38	92.50	111.64		
	UA8	10.29	20.85	37.03	41.09	73.17		
	EC3	53.13	55.68	60.74	79.81	83.54		
İsviçre	YH3	26.52	29.92	40.61	38.47	30.52	N/A	
	UA4	48.79	61.23	81.99	80.57	66.89	N/A	
	UA8	80.59	96.17	144.18	131.2216	7.101	N/A	
	EC3	9.31	11.09	6.69	8.72	10.51	N/A	
Türkiye	YH3	15.92	25.94	25.26	33.09	7.36		
	UA4	15.47	24.59	25.01	34.10	3.01		
	UA8	23.10	22.40	23.50	10.18	13.87		
	EC3	29.42	38.86	38.86	54.15	57.98		
	YH3	35.80	29.01	22.89	19.46	23.29	21.21	25.50

Birleşik Krallık	UA4	45.34	33.79	29.01	14.56	24.19	21.45	22.44
	UA8	65.04	56	48.44	40.12	42.20	42.75	59.08
	EC3	20.65	18.18	17.42	17.61	18.69	27.44	25.28
Amerika	YH3	51.69	79.22	N/A	N/A	N/A		
	UA4	247.15	464.13	N/A	N/A	N/A		
	UA8	61.76	58.67	N/A	N/A	N/A		
	EC3	317.30	574.04	N/A	N/A	N/A		


Tablo 3.6. Çok Katmanlı Ağlar ile Yapılan Öngörülerin Gerçek Değerler ile Karşılaştırılması

Ülke	Yıl	Kod	Gerçek Değer	Öngörü Değerleri
Avustralya	2021	YH3	6.750.072.092	3.578.883.197
		UA4	279.2	205
		UA8	1.5	2
		EC3	1.0	2
Avusturya	2021	YH3	2.249.500.000	2.081.972.250
		UA4	250.6	300
		UA8	0.7	0.66
		EC3	2	2.68
Belçika	2021	YH3	1.137.261.091	1.265.218.753
		UA4	93.7	129.42
		UA8	0.6	0.44
		EC3	5.1	4.38
Kanada	2019	YH3	1.366.359.292	451.142.540
		UA4	39.5	18
		UA8	0.6	1.38
		EC3	2.7	0.59
Çek Cumhuriyeti	2021	YH3	1.448.913.705	332.320.270
		UA4	120.8	34.60
		UA8	1.4	2.26
		EC3	0.4	0.84
Estonya	2021	YH3	60.000.000	48.809.500
		UA4	44.1	43.41
		UA8	1.1	1.55
		EC3	1.6	1.39
Finlandiya	2021	YH3	606.000.000	279.084.000
		UA4	110.6	70.19
		UA8	0.8	0.86
		EC3	2.3	1.84
Fransa	2021	YH3	11.557.639.689	8.907.433.981
		UA4	151.6	124.54
		UA8	0.9	0.78
		EC3	2.8	6.81
Almanya	2021	YH3	10.078.000.000	9.447.492.000
		UA4	119.6	135.76
		UA8	0.8	0.62
		EC3	2.9	3.14
Yunanistan	2021	YH3	49.384.983	-2.966.018.547
		UA4	5.0	-366767.56
		UA8	0.4	-0.80
		EC3	4.2	2.81
		YH3	645.515.782	118.142.583

Macaristan	2021	UA4	64.6	8.61
		UA8	1.6	0.52
		EC3	0.8	1.70
İrlanda	2019	YH3	71.888.966	166.181.549
		UA4	15.0	58.03
		UA8	0.3	0.71
		EC3	9.6	6.17
İtalya	2020	YH3	9.768.000.000	11.025.259.375
		UA4	172.7	178.67
		UA8	0.9	0.60
		EC3	1.6	1.99
Japonya	2019	YH3	17.559.893.925	12.173.704.618
		UA4	138.4	65.47
		UA8	1.1	0.63
		EC3	2.1	1.40
Kore	2019	YH3	6.278.662.977	6.457.204.398
		UA4	134.7	187.38
		UA8	1.3	1.74
		EC3	2.9	3.04
Letonya	2021	YH3	83.590.000	69.923.000
		UA4	45.0	46.20
		UA8	0.8	1.06
		EC3	3.5	6.49
Litvanya	2021	YH3	109.000.000	46.932.500
		UA4	35.4	13.01
		UA8	1.0	2.72
		EC3	1.6	1.90
Lüksemburg	2020	YH3	265.778.926	332.502.708
		UA4	427.2	1.76
		UA8	0.8	0.60
		EC3	21.9	4.09
Meksika	2021	YH3	484.122.592	419.093.005
		UA4	4.3	6.20
		UA8	0.2	0.48
		EC3	2.4	1.47
Yeni Zelanda	2021	YH3	163.871.580	-2.550.252
		UA4	32.0	17.35
		UA8	0.5	0.60
		EC3	3.0	7.07
Norveç	2020	YH3	1.476.857.377	1.040.775.798
		UA4	321.8	343.50
		UA8	1.5	1.55
		EC3	1.4	5.04
Polonya	2021	YH3	683.829.974	770.142.444
		UA4	18.9	18.27
		UA8	0.7	2.10
		EC3	0.6	0.46
Slovenya	2021	YH3	377.000.000	371.598.625
		UA4	179.1	198.31
		UA8	1.3	1.12
		EC3	0.3	0.56
İspanya	2021	YH3	2.519.000.000	407.080.625
		UA4	49.8	86.46
		UA8	0.5	0.14
		EC3	2.5	5.41
İsveç	2021	YH3	2.269.044.239	1.566.203.148
		UA4	220.8	170.35
		UA8	1.0	0.83

		EC3	3.1	3.07
İsviçre	2020	YH3	3.797.066.243	4.334.827.528
		UA4	481.4	577.31
		UA8	1.3	1.21
		EC3	6.1	14.62
Türkiye	2021	YH3	2.184.971.147	2.609.980.587
		UA4	30.9	38.71
		UA8	0.9	1.11
		EC3	2.0	1.77
Birleşik Krallık	2019	YH3	13.298.360.880	2.484.199.830
		UA4	241.3	48.48
		UA8	0.9	0.47
		EC3	10.4	6.40
Amerika	2021	YH3	8.650.612.590	6.950.411.397
		UA4	24.0	30.34
		UA8	0.5	0.55
		EC3	1.3	1.11


Tablo 3.5.'ye göre Avustralya için ÇKA ile yapılan analizde her dört değişken için de doğru tahminler içeren kabul edilebilir öngörü modelleri oluşturulduğu saptanmıştır. Bu doğrultuda 2021 yılı için yapılan öngöründe YH3 değişkeni haricinde ÇKA ile gerçekleştirilen öngörülerin gerçeğe daha yakın olduğu Tablo 3.6.'da görülmektedir. Şekil 3.5.'de ise ÇKA ile her bir değişkenin 2021-2025 yılları arasındaki öngörü değerleri yer almaktadır. Buna göre Avustralya'da YH3'ün eskisine göre daha az olsa da artışa geçeceği ve UA4'ün yıllar itibari ile artış göstereceğini söylemek mümkündür. UA8, 2021 yılındaki artıştan sonra düşüşe geçecek ve 2024'ten itibaren yeniden artmaya başlayacaktır. EC3 ise eskisine göre her zaman daha düşük düzeylerde seyredecektir.



Şekil 3.5. ÇKA ile Avustralya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri


Avusturya için ÇKA ile yapılan analizde YH3 ve UA4 değişkenleri için kabul edilebilir öngörü modelleri oluşturulduğu ancak UA8 değişkeni için birinci adımdan sonra ve EC3 değişkeni için hatalı modeller oluşturulduğu Tablo 3.5.'de görülmektedir. Tablo 3.6.'da da görülmektedir ki 2021 yılı için yapılan öngöründe ÇKA ile gerçeğe yakın

sonuçlar elde edilmiştir. Şekil 3.6.'da görüldüğü üzere YH3 ve UA4'te 2025 yılına kadar azalışlar gerçekleşecek iken EC3 2020 yılındaki ciddi azalıştan artışa geçecektir.




Şekil 3.6. ÇKA ile Avusturya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri

Belçika'nın UA4 ve UA8 değişkenleri için ÇKA ile kurulan modellerin hatalı olduğu Tablo 3.5.'de görülür iken, YH3 ve EC3 değişkenleri için doğru tahminler içeren öngörü modelleri oluşturulmuştur. Tablo 3.6.'da 2021 yılı için yapılan öngörü değerlerinde de ÇKA ile EC3 değişkeni için yapılan öngörünün gerçek değerlere yakın olduğu açıkça görülmektedir. 2021 yılından itibaren YH3 değişkeninde artış yaşanacak iken EC3'ün azalışa geçeceği Şekil 3.7.'de görülmektedir.




Şekil 3.7. ÇKA ile Belçika'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri

Tablo 3.5.'de de görüldüğü üzere Kanada için ÇKA kullanılarak sadece YH3 ve UA4 değişkenleri için kabul edilebilir modeller oluşturulabilmiştir. Nitekim Tablo 3.6.'da YH3 ve UA4 değişkeni için ÇKA ile yapılan öngörülerin gerçeğe yakın olduğu görülmektedir. Bu kapsamda YH3 ve UA4'ün büyük bir azalış sonrası yükselişe geçtikten sonra 2023 yılı sonrası UA4'te azalış yaşanacağı Şekil 3.8.'de görülmektedir.




Şekil 3.8. ÇKA ile Kanada’ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2019-2025 Yılları Arasındaki Öngörü Değerleri

Çek Cumhuriyeti için ÇKA ile yapılan analizde YH3 değişkeni için kabul edilebilir bir öngörü modeli oluşturulur iken; UA4 ve UA8 değişkenleri için hatalı modeller oluşturulduğu Tablo 3.5.’de görülmektedir. Şekil 3.9.’da görüldüğü üzere 2021 yılında azalışa geçen YH3, 2022 yılındaki toparlanmanın ardından yeniden azalışa geçse de 2025 yılında artışa geçecektir.




Şekil 3.9. ÇKA ile Çek Cumhuriyeti’ne Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri

ÇKA ile Estonya’ya ait dört taşımacılık değişkeninin hepsi için kabul edilebilir öngörü modelleri oluşturulduğu Tablo 3.5.’de görülmekte iken; 2021 yılı için yapılan analizde öngörü değerlerinin gerçek değerlere yakınlığı Tablo 3.6.’da görülmektedir. Şekil 3.10.’da görüldüğü üzere 2021 yılında artışa geçen YH3, UA4 ve UA8 birlikte hareket etmektedirler. YH3’te 2025’e kadar azalış yaşanır iken; UA4 ve UA8’te 2022 ile 2024 yıllarında azalış görülmektedir. Fakat EC3 haricinde tüm değişkenler 2025 yılında yeniden yükselişe geçeceklerdir. EC3 ise yaşadığı yükseliş sonrası tekrar düşüşe geçecektir.




Şekil 3.10. ÇKA ile Estonya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri

Finlandiya'nın YH3 ve EC3 değişkenleri için ÇKA ile kurulan modellerin hatalı, UA4 için kurulan modelin kabul edilebilir, UA8 için kurulan modelin ise kabul edilebilir ve iyi olduğu Tablo 3.5.'de görülmektedir. Bu doğrultuda Tablo 3.6.'da açıkça görülmektedir ki YH3 EC3 değişkenlerinin ÇKA ile 2021 yılı için yapılan öngörüsü gerçek değerlere oldukça uzaktır. Şekil 3.11.'de ise UA4'ün 2021 yılındaki azalışın ardından tekrar yükselişe geçeceği; UA8'in ise 2023 yılındaki artışın ardından düşüşe geçeceği görülmektedir.



Şekil 3.11. ÇKA ile Finlandiya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri

Fransa'nın YH3 değişkeni için ÇKA ile kurulan öngörü modelinde öngörülen adım sayısı arttıkça modelin iyiden hatalıya dönüştüğü Tablo 3.5.'de görülmektedir. UA4 değişkeni için ÇKA ile kurulan modelde de benzer şekilde adım sayısı arttıkça hatalı modeller oluşmuştur. UA8 ve EC3 değişkenleri için ise hatalı modeller kurulmuştur. Şekil 3.12.'de görüldüğü üzere 2023 yılına kadar düşüşe geçen UA4, 2024'te yükseldikten sonra tekrar düşecektir.




Şekil 3.12. ÇKA ile Fransa'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri

Almanya'ya ait dört değişkenin ÇKA ile öngörülmesi için oluşturulan modellerin hepsinde adım sayısı arttıkça kabul edilebilir modellerin hatalı modellere dönüştüğü Tablo 3.5.'de görülmektedir.

Yunanistan için ÇKA ile kurulan tüm modellerin hatalı olduğu Tablo 3.5.'de görülmektedir. Ayrıca 2021 yılı için yapılan analizde de öngörü değerlerinin gerçek değerlerden oldukça uzak olduğu Tablo 3.6.'da görülmektedir.


ÇKA ile Macaristan'ın YH3 değişkeni için yapılan analizde adım sayısı arttıkça hatalı modellerin meydana geldiği; diğer üç değişken için ise hatalı modeller olduğu Tablo 3.5.'de görülmektedir. Tablo 3.6.'da da elde edilen öngörü değerlerinin gerçek değerlerden uzak olduğu görülmektedir.

İrlanda'ya ait YH3, UA4, UA8 değişkenleri için ÇKA ile kurulan modellerin hatalı olduğu; EC3 değişkeni için kurulan modelde de adım sayısı arttıkça MAPE değerinin düştüğü Tablo 3.5.'de görülmektedir. EC3'ün 2024 yılındaki düşüş sonrasında 2025'te tekrar artışa geçerek 2018 yılındaki seviyelere yaklaşacağı Şekil 3.13.'de görülmektedir.




Şekil 3.13. ÇKA ile İrlanda'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2019-2025 Yılları Arasındaki Öngörü Değerleri

ÇKA ile İtalya'ya ait YH3, UA4 ve UA8 için kurulan modeller hatalı iken EC3 değişkeni için kurulan modelin kabul edilebilir nitelikte olduğu Tablo 3.5.'de görülmektedir. EC3'ün 2021 yılından itibaren ciddi şekilde azalışa geçeceği ve EC3'te 2025 yılı itibari ile artış yaşanacağı Şekil 3.14.'de görülmektedir.




Şekil 3.14. ÇKA ile İtalya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2020-2025 Yılları Arasındaki Öngörü Değerleri

Japonya'nın YH3 değişkeninin ÇKA ile öngörülmesinde birinci adım haricinde hatalı sonuçlar mevcut iken; diğer üç değişken için kurulan modellerin hepsinin hatalı olduğu Tablo 3.5.'de görülmektedir. Bu kapsamda ÇKA ile yapılan öngöründe YH3'ün 2019 yılında azalışa geçeceği Şekil 3.15.'de gösterilmiştir.




Şekil 3.15. ÇKA ile Japonya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2019-2025 Yılları Arasındaki Öngörü Değerleri

ÇKA ile Kore'ye ait YH3 değişkeni için ve UA4 değişkeninde birinci adım için kabul edilebilir bir öngörü mevcut iken sonraki adımlarda hatalı modeller olduğu belirlenmiştir. EC3 değişkeni için iyi ve UA8 değişkeni için hatalı öngörü modelleri oluşturulduğu ise Tablo 3.5.'de görülmektedir. Şekil 3.16.'da görülmektedir ki; ÇKA ile yapılan analizde EC3 için artış öngörülmüştür.




Şekil 3.126. ÇKA ile Kore'ye Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2019-2025 Yılları Arasındaki Öngörü Değerleri

Tablo 3.5.'de görüldüğü üzere ÇKA ile Letonya'ya ait yalnızca EC3 değişkeni için kabul edilebilir öngörü modeli oluşturulabilmiştir. Bu doğrultuda ÇKA ile 2021 yılı için yapılan analizde EC3 değişkeni için gerçeğe yakın bir öngöründe bulunduğu Tablo 3.6.'da yer almaktadır. EC3'ün 2021'de ciddi şekilde artışa geçtikten sonra 2022 yılında düşüşe geçeceği fakat sonra tekrar yükseliş trendinin başlayacağı ise Şekil 317.'de görülmektedir.




Şekil 3.17. ÇKA ile Letonya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri

ÇKA ile Litvanya için yapılan analizde yalnızca UA8 için hatalı bir öngörü modeli oluşturulduğu; diğer üç değişken için ise kabul edilebilir öngörü modellerinin varlığı Tablo 3.5.'de görülmektedir. Şekil 318.'de görüldüğü üzere ÇKA; YH3, UA4 ve EC3'ün 2025 yılında yükselişe geçeceğini öngörmüştür.




Şekil 3.18. ÇKA ile Litvanya’ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri

Lüksemburg’a ait YH3 ve EC3 değişkenleri için ÇKA ile yapılan analizde kabul edilebilir öngörü modelleri oluşturulduğu fakat UA4 ve UA8 değişkenleri için hatalı modellerin kurulduğu Tablo 3.5.’de gösterilmiştir. Aynı zamanda UA4 ve UA8 için yapılan öngörü sonuçlarının da gerçek değerlerden oldukça uzak olduğu Tablo 3.6’da görülmektedir. YH3’ün 2022 yılında başlayan azalışının 2024’te son bularak artışa geçeceği, EC3’te başlayan azalışın ise 2022’den itibaren son bulacağı ve artışa geçeceği Şekil 3.19.’da görülmektedir.



Şekil 3.19. ÇKA ile Lüksemburg’a Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2020-2025 Yılları Arasındaki Öngörü Değerleri


ÇKA ile Meksika’ya ait YH3 değişkeni için yapılan analizde kabul edilebilir öngörü modeli oluşturulduğu ve UA4 değişkeni için yapılan analizde öngörülen adım sayısı attıkça MAPE değerinin arttığı Tablo 3.5.’de görülmektedir. Diğer değişkenler için ise hatalı modeller kurulmuştur. 2021 yılı için kurulan öngörü modellerinde ise YH3 değişkeni için ÇKA ile gerçeğe yakın sonuçlar elde edildiği Tablo 3.6.’da görülmektedir. 2022 ile 2023 yıllarında azalışa geçen YH3’ün 2024 sonrası yükselişe geçeceği Şekil 3.20.’de görülmektedir.



Şekil 3.20. ÇKA ile Meksika'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri

Yeni Zelanda için ÇKA ile kurulan tüm modellerin hatalı olduğu Tablo 3.5.'de görülmektedir. 2021 yılı için yapılan öngörülerin ise gerçek değerlerden oldukça uzak olduğu ise Tablo 3.6.'da görülmektedir.

Norveç' e ait YH3 ve EC3 değişkenleri için ÇKA ile yapılan analizde öngörülen adım sayısı arttıkça iyi modellerin kabul edilebilir modellere dönüştüğü; diğer iki değişken için ise kabul edilebilir modeller oluşturulduğu Tablo 3.5.'de görülmektedir. Şekil 3.21.'ye göre 2020 yılında YH3 azalışa geçer iken, UA4'te yaşanan artış sonrası yıllar itibari ile önemli değişimler olmayacağı söylenebilir. UA8'de 2023 ve 2025 yıllarında, EC3'te ise 2022 ve 2025 yıllarında keskin düşüşler yaşanacağı öngörülmüştür.




Şekil 3.21. ÇKA ile Norveç'e Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2020-2025 Yılları Arasındaki Öngörü Değerleri

Polonya için ÇKA ile kurulan tüm modellerin hatalı olduğu Tablo 3.5.görülmektedir. 2021 yılı için yapılan analizde öngörü değerlerinin gerçek değerlere yakın olmadığı ise Tablo 3.6.'da gösterilmiştir.


Slovenya için ÇKA ile kurulan tüm modellerin hatalı olduğu Tablo 3.5.'de görülmektedir. 2021 yılı için yapılan analizde öngörü değerlerinin gerçek değerlere yakın olmadığı ise Tablo 3.6.'da gösterilmiştir.

ÇKA ile İspanya'nın YH3 değişkeni için yapılan öngöründe ilk adım için hatalı öngörü modeli oluşsa da adım sayısı arttıkça MAPE değerinin düştüğü fakat UA8 değişkeni için yapılan öngöründe tam tersine adım sayısı arttıkça MAPE değerinin arttığı Tablo 3.5.'de görülmektedir. Tablo 3.6.'da görüldüğü üzere 2021 yılında UA8 değişkeni için ÇKA ile gerçeğe yakın öngörülerde bulunulmuştur. 2021 yılı için hatalı bir öngörü modeli kurulmuş olsa da diğer yıllar için doğru öngörüler mevcut olan YH3'ün yıllar itibari ile artışa geçeceği Şekil 3.22.'de görülmektedir.




Şekil 3.22. ÇKA ile İspanya'ya Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri

İsveç'e ait YH3 değişkeni için ÇKA ile ilk üç adım için kabul edilebilir öngörü modelleri oluşturulur iken sonrasında hatalı modeller oluşturulduğu; UA8 değişkeni için ise ilk adımda iyi, sonraki üç adımda kabul edilebilir ve son adımda hatalı model oluşturulduğu Tablo 3.5.'de görülmektedir. 2021 yılında YH3 ve UA8 değişkenleri için ÇKA ile gerçeğe yakın öngörüler elde edildiği Tablo 3.6.'da görülmektedir. YH3'ün 2021-2023 yılları arasında azalışa geçeceği, UA8'de ise 2021'de yaşanan azalış sonrasında 2022 yılında artış yaşanacağı ve sonraki yıllarda sürekli bir azalış yaşanacağı Şekil 3.23.'de gösterilmiştir.



Şekil 3.23. ÇKA ile İsveç'e Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri


İsveç'e ait YH3 değişkeni için ÇKA ile kabul edilebilir öngörü modelleri oluşturulur iken UA4 değişkeni için birinci adım haricinde hatalı öngörü modelleri oluşturulmuştur. UA8 için hatalı modeller oluşturulur iken EC3 için çok iyi ve iyi öngörü modelleri oluşturulduğu Tablo 3.5.'de görülmektedir. 2020 yılı için yapılan öngöründe ÇKA ile YH3 ve EC3 değişkenleri için gerçeğe yakın sonuç elde edildiği Tablo 3.6.'da gösterilmiştir. ÇKA ile yapılan öngörüye göre YH3 2020 yılından itibaren artışa geçeceği ve bu artışın 2023 yılında son bulacağı; EC3'te yaşanan azalışın ise 2023'ten itibaren son bulacağı Şekil 3.24.'de görülmektedir.



Şekil 3.24. ÇKA ile İsveç'e Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2020-2025 Yılları Arasındaki Öngörü Değerleri


Tablo 3.5.'ye göre Türkiye'nin YH3, UA4 ve UA8 değişkenleri için ÇKA ile kurulan modeller iyi ve kabul edilebilir nitelikte iken, EC3 değişkeni için oluşturulan model kabul edilebilirdir. 2021 yılı için yapılan analizlerde öngörü değerlerinin gerçek değerlere yakın olduğu Tablo 3.6.'da görülmektedir. Şekil 3.25.'de görüldüğü üzere ÇKA, YH3 ve UA4'ün birlikte hareket ettiğini ve her ikisinin de 2024 yılı itibari ile azalışa geçeceğini öngörmüştür. Aynı zamanda UA8'in aynı YH3 ve UA4 gibi 2023

yılında artışa geçeceğini fakat bu artışın 2025'te de devam edeceğini öngörmüştür. ÇKA, EC3 için 2023 yılı sonrasında sürekli bir artış öngörmüştür.



Şekil 3.25. ÇKA ile Türkiye'ye Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2021-2025 Yılları Arasındaki Öngörü Değerleri

Birleşik Krallık için ÇKA ile YH3 ve UA4 değişkenleri için kabul edilebilir öngörü modelleri oluşturulur iken; UA8 için genelde hatalı modeller oluşturulduğu görülmüştür. EC3 için ise iyi ve kabul edilebilir modeller oluşturulduğu Tablo 3.5.'de gösterilmiştir. Şekil 3.26.'da görüldüğü üzere YH3 ile UA4 yıllar itibari ile birlikte hareket etmekte ve her iki değişkende de 2019 yılı itibari ile yaşanan artış 2022 yılında son bulmaktadır. ÇKA, her iki değişken için de 2025'te yeniden yükseliş öngörmüştür. ÇKA, EC3 için ise 2022 sonrası artış öngörmüştür.



Şekil 3.26. ÇKA ile Birleşik Krallık'a Ait YH3, UA4, UA8 ve EC3 değişkenlerinin 2019-2025 Yılları Arasındaki Öngörü Değerleri

Amerika için ÇKA ile kurulan tüm modellerin hatalı olduğu Tablo 3.5.'de görülmektedir. Tablo 3.6.'ya göre ise öngörü değerleri gerçek değerlerden uzaktır.

3.4. Tartışma

29 OECD üyesi ülkeye ait demiryolu altyapı yatırımı, kişi başına düşen demiryolu altyapı yatırımı, GSYH başına düşen toplam iç ulaşım altyapı yatırımı ile uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payı olmak üzere dört adet değişkenin 2025 yılına kadar ileriye yönelik öngörülerinin YSA türlerinden ÇKA ile gerçekleştirilerek öngörü modellerinin oluşturulması bu çalışmanın amacıdır. Bu amaç doğrultusunda çalışmada elde edilen ilk ve en önemli bulgu; ÇKA ile kurulan modellerin çoğunluğunun MAPE değerinin oldukça düşük olduğudur. Bu sonuç literatürde taşımacılık göstergelerinin tahminini YSA ve doğrusal regresyon kullanarak gerçekleştiren Gosasang et al., (2011); Şen et al., (2021); Islam, et al., (2022)'nin elde ettiği sonuçlar ile benzerdir. Ayrıca yapay sinir ağlarının tahmin performansını Box Jenkis ile karşılaştıran Özdemir (2021) ve VAR ile karşılaştıran Mutascu (2022)'de bu çalışmada elde edilen sonuçlara benzer şekilde YSA'nın sonuçlar ürettiğini saptamışlardır. Bu sonuç açıkça göstermektedir ki; insan beynini ve sinir sistemini taklit eden yapay sinir ağlarının hata toleransı oldukça yüksektir. Bu durum YSA'nın karmaşık ve doğrusal olmayan ilişkileri daha iyi keşfedebilmesine ve gerçeğe daha yakın tahminlerde bulunabilmesine sebebiyet vermektedir.

Çalışmada elde edilen ikinci önemli bulgu; Avustralya, Avusturya, Belçika, Kanada, Çek Cumhuriyeti, Estonya, Litvanya, Lüksemburg, Meksika, Norveç, Japonya, İspanya, İsveç, İsviçre, Türkiye ve Birleşik Krallık'ta demiryolu altyapı yatırımları 2019-2023 döneminde belirli yıllarda azalış gösterse de Belçika ve Türkiye haricinde bahsedilen diğer ülkelerin demiryolu altyapı yatırımlarının 2025 yılında artışa geçeceği. Öyle ki Avustralya'da demiryolu altyapı yatırımları 2021 yılında 6.750.072.092 Euro (€) iken bu rakam ÇKA'nın tahmin ettiği üzere artışa geçmiş ve 2022 ile 2023 yıllarında sırası ile 7.754.754.825 ve 9.241.323.121 € şeklinde gerçekleşmiştir. Yine ÇKA ile yapılan öngöründe Belçika'nın demiryolu altyapı yatırımlarında 2021-2023 yılları arasında küçük çaplı artışlar yaşanacağı öngörülmüştür. Nitelim ilgili yıllarda sırası ile 1.137.261.091, 1.140.000.000 ve 1.148.204.885 € olarak gerçekleşen demiryolu altyapı yatırımları öngörü sonuçlarını doğrular niteliktedir. Çek Cumhuriyeti için ÇKA ile yapılan öngörülerini doğrular nitelikte 2022 yılında 1.737.852.298 € olan demiryolu altyapı yatırımları 2023 yılında azalarak 1.678.670.533 olarak gerçekleşmiştir. ÇKA Türkiye'de ise demiryolu altyapı yatırımlarının 2023 yılında bir önceki yıla göre

artacağını öngörmüştür. Bu doğrultuda Türkiye’de 2022 yılında 2.648.168.523 € olan demiryolu altyapı yatırımları 2023 yılında 2.870.157.531 € olarak gerçekleşmiştir. Aynı zamanda Litvanya’da 2020 yılında 174.000.000 € olan demiryolu altyapı yatırımlarının 2021 yılında düşüşe geçeceği öngörülmüştür. Nitekim 2021 yılında Litvanya’da demiryolu altyapı yatırımları 109.000.000 €’ya gerilemiştir. Benzer şekilde ÇKA ile yapılan öngöründe 2.408.000.000 € olan demiryolu altyapı yatırımlarının İspanya’da 2021 yılında bir önceki yıla göre azalacağı ve 2022 ile 2023 yıllarında yeniden artacağı öngörülmüştür. Öyle ki ÇKA ile yapılan öngörü bulgularını destekler nitelikte 2021 yılında İspanya’da demiryolu altyapı yatırımları bir önceki yıla göre azalarak 2.343.000.000 € olur iken; 2022 ve 2023 yıllarında artışa geçerek sırası ile 2.824.000.000 € ve 3.910.000 € olmuştur (<https://data-explorer.oecd.org/> Erişim Tarihi: 14.10.2025). İlgili dönemde Covid-19 pandemisinin yarattığı ekonomik kriz dikkate alındığında hükümetlerin altyapı yatırımlarını gözden geçirerek ertelediklerini veya sonlandırdıklarını söylemek mümkündür. Bu durum yukarıda bahsedilen ülkelerde ulaşım altyapı yatırımlarının 2021 yılında azalması ile sonuçlanmıştır.

Çalışmada elde edilen üçüncü bulgu; kişi başına düşen demiryolu altyapı yatırımlarının Avustralya, Avusturya, Litvanya, Norveç ve Birleşik Krallık’ta 2025 yılında artacağı şeklinde iken; Kanada ve Finlandiya, Fransa ve Türkiye’de ise aynı yıl düşüş öngörülmüştür. ÇKA’nın öngördüğü şekilde kişi başına düşen demiryolu altyapı yatırımları Avustralya’da her yıl artış göstermiş ve 2022 yılında en son 2023 yılında 329 dolar (\$) olarak gerçekleşmiştir. ÇKA, 2022 yılında Avusturya’da kişi başına düşen demiryolu altyapı yatırımlarının düşüşe geçeceğini doğru şekilde öngörmüştür. Nitekim Avusturya’da kişi başına düşen demiryolu altyapı yatırımları 2021 yılında 250.6 \$ iken, 2022 yılında 228.9 \$’a gerilemiştir. Fakat ÇKA’nın öngördüğü şekilde düşüş eğilimi 2023 yılında sürmemiştir ve 2023 yılında kişi başına düşen demiryolu altyapı yatırımı 241.5 \$ olmuştur. Bu durum Avusturya’da kişi başına düşen demiryolu altyapı yatırımlarında 2025 yılında da artış eğiliminin süreceğine dair güçlü bir beklenti oluşturmaktadır. Benzer şekilde ÇKA, Litvanya için yapılan öngöründe kişi başına düşen altyapı yatırımlarının 2020 (60.3 \$) yılına göre 2021 (35.4 \$) yılında düşüşe geçeceğini doğru öngörür iken; 2022 (42.2 \$) ve 2023 (80.7 \$) yılı için azalış eğiliminin süreceğine dair hatalı bir öngöründe bulunmuştur. Fakat Litvanya’da 2022 ve 2023 yıllarında kişi başına düşen demiryolu altyapı yatırımlarında süren bu artış eğilimi ÇKA’nın 2025 yılı için yaptığı öngörüyle destekler niteliktedir. Aynı zamanda ÇKA, demiryolu altyapı yatırımlarının

Fransa'daki düşüş eğilimini doğru öngörmüştür. Öyle ki Fransa'da kişi başına düşen demiryolu altyapı yatırımları 2020 yılında 161.5 \$ iken bu rakam 2021 yılında 151.6 \$, 2022 yılında ise 145.3 \$ olarak gerçekleşmiştir. Bu rakamlar 2025 yılında da düşüş eğiliminin süreceğine dair beklenti oluşturmaktadır. Türkiye için de kişi başına düşen demiryolu altyapı yatırımları ÇKA ile doğru şekilde öngörülmüştür. Nitekim 2021 yılında 30.9 \$ olarak gerçekleşen kişi başına düşen demiryolu altyapı yatırımları 2022' de azalarak 29.4 \$'a geriler iken, 2023' de ise artarak 30.8 \$'a yükselmiştir (<https://data-explorer.oecd.org/> Erişim Tarihi: 14.10.2025).

Dördüncü olarak çalışmada; İsveç'te 2022 yılı, Finlandiya'da ise 2023 yılı sonrasında GSYH başına düşen toplam iç ulaşım altyapı yatırımlarında sürekli azalış yaşanacağı tespit edilir iken, Norveç'te 2023 ve 2025 yıllarında keskin düşüşler olacağı öngörülmüştür. Türkiye'de 2022 yılındaki azalış sonrasında, Estonya'da ise 2022 ve 2024 yıllarında yaşanan azalış sonrasında GSYH başına düşen toplam iç ulaşım altyapı yatırımlarında 2025 yılında yükseliş olacağı tahmin edilmiştir. Nitekim İsveç'te 2021' de 1.0 olarak gerçekleşen GSYH başına düşen toplam iç ulaşım altyapı yatırımları ÇKA'nın öngördüğü şekilde 2022 ve 2023 yıllarında düşüşe geçmiş ve her iki yılda da 0.9 olarak gerçekleşmiştir. Bu durum İsveç'te 2025 yılında da GSYH başına düşen toplam iç ulaşım altyapı yatırımlarında azalış yaşanacağına dair önemli bir kanıt sunmaktadır. Benzer şekilde ÇKA, Estonya'da GSYH başına düşen toplam iç ulaşım altyapı yatırımlarının 2022 yılında azalacağını doğru tahmin etmiştir. Öyle ki Estonya'da GSYH başına düşen toplam iç ulaşım altyapı yatırımları 2021 yılında 1.1 iken; 2020 yılında 1.0'a gerilemiştir. Türkiye'de ise, 2022 yılında azalış öngörülse de gerçekte hem 2021 hem de 2022 yıllarında GSYH başına düşen toplam iç ulaşım altyapı yatırımları 0.9 olarak gerçekleşmiştir (<https://data-explorer.oecd.org/> Erişim Tarihi: 14.10.2025).

Çalışmada elde edilen önemli bulgulardan sonuncusu; Avusturya, İrlanda, İtalya, Letonya, Litvanya, Lüksemburg, İsviçre, Türkiye ve Birleşik Krallık'ta 2025 yılında uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının artacağı; Avustralya, Estonya ve Norveç'te ise azalacağıdır. Hava taşımacılığında kaynaklanan CO₂ emisyonlarının toplam taşımacılıktan kaynaklanan CO₂ emisyonları içerisindeki payına ilişkin gerçek değerler incelendiğinde ÇKA'nın Avustralya ve Norveç'te yaşanan düşüş eğilimini doğru öngördüğü söylenebilir. Nitekim 2019-2021 döneminde hava taşımacılığında kaynaklanan CO₂ emisyonlarının toplam taşımacılıktan kaynaklanan CO₂ emisyonları

içerisindeki payı sırası Avustralya’da ile 9.1, 7.8, 5.6, Norveç’te 7.7, 5.4 ve 6.0 olarak gerçekleşmiştir. Estonya’da ise her üç yılda da hava taşımacılığından kaynaklanan CO₂ emisyonlarının toplam taşımacılıktan kaynaklanan CO₂ emisyonları içerisindeki payı 2.0 olarak gerçekleşmiştir (<https://data-explorer.oecd.org/> Erişim Tarihi: 14.10.2025). Nitekim COVID-19 salgını, küresel ölçekte hava taşımacılığını önemli ölçüde etkileyerek özellikle 2020 ve 2021 yıllarında havacılık emisyonlarında önemli bir azalmaya yol açmıştır (<https://aviationbenefits.org/other-environmental-challenges/climate-action/market-based-measures/corsia/corsia-explained/> Erişim tarihi: 20.10.2025). Fakat Uluslararası Enerji Ajansı (International Energy Agency (IEA)), COVID-19 salgını sonrasında uluslararası seyahatlerde yaşanan toparlanma ile birlikte 2022 yılında hava taşımacılığının diğer taşıma modlarına kıyasla daha yüksek bir büyüme gerçekleştirerek küresel CO₂ emisyonlarına %2 katkıda bulunduğunu belirtmiştir (https://climate.ec.europa.eu/eu-action/transport-decarbonisation/reducing-emissions-aviation_en Erişim tarihi: 20.10.2025). Bu kapsamda havacılık da dahil olmak üzere tüm sektörlerin AB’nin çevre politikasına uyumlu olması gerekmektedir. AB’nin günümüzdeki çevre politikası, kirliliği azaltmayı, önlemeyi ve hatta ortadan kaldırmayı, doğal kaynakların ise ekolojik sisteme zarar vermeyecek şekilde kullanılmasını garanti ederek sürdürülebilir kalkınmayı amaçlamaktadır. Aynı zamanda çevreyi korumak adına geliştirilen politikaların ulaştırma ve enerji sektörlerindeki politikalar ile entegrasyonu istenmektedir. Bu kapsamda AB, 1 Aralık 2019 tarihinde, Avrupa Komisyonu Başkanı Ursula Von Der Leyen tarafından 1 Aralık 2019 tarihinde açıklanan Avrupa Yeşil Mutabakatı (AYM) ile çevre politikasını hayata geçirmiştir. Öyle ki AB, AYM çerçevesinde 2050 yılına kadar Avrupa’da sera gazı emisyonlarını sıfırlamayı hedeflemektedir. Bu kapsamda AYM üretim, ticaret, tarım, ulaştırma ve çevre gibi pek çok sektörde köklü bir değişimi öngörmektedir (<https://www.ab.gov.tr/p.php?e=92> Erişim tarihi: 20.10.2025). Bu nedenle AB, yıllar itibari ile sera gazı emisyonlarının azaltılarak temiz enerjinin ve enerji verimliliğinin teşvik edilmesi amacı ile bir dizi politikayı hayata geçirmiştir. Bu politikalardan birisi de Sınırdaki Karbon Düzenleme Mekanizmasıdır. Sınırdaki Karbon Düzenleme Mekanizması ile 2005’te AB’de faaliyete geçen Emisyon Ticaret Sistemine (ETS) eşdeğer olacak şekilde bir karbon fiyatlandırmasının Sınırdaki Karbon Düzenleme Mekanizması kapsamında yer alan ürünlerin ithalatında da uygulanması öngörülmüştür. Aynı zamanda ETS uygulamasını daha sıkı hale getirecek mevzuat düzenlemeleri de mevcuttur. Nitekim mevzuat güncellemesi ile ETS kapsamında yer alan sektörlerde 2005 yılına nazaran 2030 yılında

emisyonların %62 azaltılması hedeflenmiştir (<https://ticaret.gov.tr/dis-iliskiler/yesil-mutabakat/ab-sinirda-karbon-duzenleme-mekanizmasi/ab-skdm-bilgi-notu> Erişim tarihi: 20.10.2025). Fakat AB'ne üye ülkelerin yanında İzlanda, Liechtenstein ve Norveç'te bulunan elektrik üretim endüstrisi ve diğer enerji yoğunluklu sektörlerdeki toplam emisyonların yaklaşık %45'ini karşılayan ve 12 bin tesisi içerisine alan ETS, Avrupa Birliği'nin emisyonlarının yaklaşık olarak %55'ini kapsamamaktadır. Tarım, inşaat, atık yönetimi ve taşımacılık bu durumdaki sektörlerdendir. Özellikle taşımacılık, sera gazı emisyonlarının en büyük kaynaklarından biridir ve uluslararası havacılık emisyonlarının 2050 yılına gelindiğinde 2005 yılındakinden yaklaşık %300-700 daha artacağı öngörülmektedir

(https://www.eeas.europa.eu/sites/default/files/documents/brochure_3_v2.pdf Erişim tarihi: 20.10.2025). Bu nedenle de Sivil Havacılık Örgütü (ICAO) tarafından geliştirilen ve 2016 yılında ICAO'nun 191 üyesi tarafından kabul edilip 1 Ocak 2019 yılı itibari ile uygulanmaya başlayan CORSIA (Uluslararası Havacılığa Yönelik Karbon Denkleştirme ve Azaltma Programı-Carbon Offsetting and Reduction Scheme for International Aviation) önemli bir yer tutmaktadır. CORSIA ile uluslararası havacılık sektörü ilk defa küresel olarak bir emisyon azaltım mekanizmasına sahip olmaktadır. Şu an için bu mekanizmanın uygulanması ise gönüllülük esasına dayanmakla birlikte 2027 yılına kadar zorunlu değildir (<https://yesilbuyume.org/corsia-nedir/> Erişim tarihi: 20.10.2025). Bu doğrultuda Avusturya, İrlanda, İtalya, Letonya, Litvanya, Lüksemburg, İsviçre, Türkiye ve Birleşik Krallık'ta ÇKA'nın uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının artacağını öngörmesi olağandır. Nitekim yukarıda da bahsedildiği üzere Covid-19 salgını sonrasında ülkelerin hava trafiği artış eğilimindedir.

3.5. Çıkarımlar

3.5.1. Teorik ve uygulama çıkarımları

Bu çalışma, popüler bir yapay sinir ağı türü olan çok katmanlı ağlar ile taşımacılık göstergelerinin ileriye yönelik göstergelerinin yapılarak 2025 projeksiyonu sunulmasına dayanmaktadır. Bu kapsamda bu çalışma, teorik katkılar açısından öncelikle yapay sinir ağlarının taşımacılık göstergelerine ilişkin öngörü modelleri oluşturulmasında kullanılabilirliğini göstermektedir. Nitekim oluşturulan öngörü modellerinin başarısı MAPE değeri kullanılarak ölçüldüğünde çoğunlukla iyi ve çok iyi nitelikte modellerin

kurulduğu saptanmıştır. Taşımacılık sektöründe doğrusal olmayan, karmaşık ilişkilerin varlığı düşünüldüğünde öngörü modellerinin oluşturulmasında geleneksel tahmin yöntemlerinden ziyade yapay sinir ağlarının kullanılması literatüre değerli katkılar sağlayacaktır. İkincisi, önceki çalışmalar çoğunlukla AB üyesi ülkeler, BRICS ile MINT ülkelerinin taşımacılık göstergelerinin tahminine odaklandığından ve OECD ülkelerinin taşımacılık göstergelerinin tahminine ilişkin ek araştırmalara ihtiyaç duyulduğundan bu çalışma literatüre katkı sunmaktadır. Üçüncüsü, mevcut çalışmalar genellikle denizcilik göstergelerine ve karayolu kazalarına ilişkin tahminler gerçekleştirdiklerinden altyapı yatırımları ile CO₂ emisyonlarına ilişkin öngörülerin gerçekleştirildiği bu çalışma literatüre yeni bir bakış açısı sunmaktadır.

Araştırmacılar ve politika yapıcılar önemli uygulama çıkarımlarına sahip olan bu çalışmadan büyük ölçüde yararlanacaklardır. Nitekim öncelikle oluşturulan 2025 projeksiyonu sayesinde OECD ülkelerinin politika belirleyicileri ulaşım altyapı yatırımlarına ve havacılıktan kaynaklı CO₂ emisyonlarına ilişkin doğru politikalar üretme imkanına sahip olacaklardır. İkincisi, araştırmacılar ve AB üyesi olan ülkeler bu çalışmada ortaya konulan 2025 projeksiyonunun Avrupa Yeşil Mutabakatı kapsamında emisyon azaltım hedefleri ile uyuşup uyuşmadığını tespit etme imkanına sahip olacaklardır. Böylelikle hem araştırmacılar hem de politika yapıcılar gerekirse alınabilecek önlemler için bir yol haritası belirleyebileceklerdir.

3.6. Sonuç ve Öneriler

Bir ülkede ulaşım sistemlerinin yarattığı yatırım, inşaat, sanayileşme gibi pozitif ve çevre kirliliği gibi negatif dışsallıklar düşünüldüğünde ulaşım altyapı yatırımlarının ileride nasıl değişeceğinin tespit edilmesinin önemi bir kez daha ortaya çıkmaktadır. Çünkü bir ülkede doğru planlanmış ulaşım altyapı yatırımları sayesinde ulaşım sistemlerinin gelişimi konusunda doğru planlamalar yapılabilecek ve böylelikle negatif dışsallıklardan ziyade pozitif dışsallıkların ortaya çıkması sağlanabilecektir.

Ulaşım altyapı yatırımlarının neden olduğu pozitif ve negatif dışsallıkların önemi düşünüldüğünde bu yatırımların gelecekte nasıl şekilleneceğinin doğrusal olmayan problemleri ortaya çıkarabilecek doğru analiz yöntemleri kullanılarak tahmin edilmesinin gerekliliği ortaya çıkmaktadır. Bu kapsamda bu çalışmanın amacı; OECD üyesi 29 ülkeye ait demiryolu altyapı yatırımı, kişi başına düşen demiryolu altyapı yatırımı, GSYH başına düşen toplam iç ulaşım altyapı yatırımı ve uluslararası havacılık sığınaklarından

kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payı olmak üzere dört farklı değişkenin her biri için 2025 yılına kadar ileriye yönelik öngörülerin WEKA 3.8.6 yazılımında yapay sinir ağı türlerinden biri olan çok katmanlı ağlar ile gerçekleştirilmesi ve model performanslarının MAPE değeri baz alınarak ölçülmesidir.

Çalışmanın sonucunda ortaya çıkan ilk ve en önemli bulgu; beklenildiği üzere YSA ile oluşturulan tahmin ve öngörü modellerinin çoğunluğunun oldukça küçük MAPE değerine sahip olduğudur. Nitekim sahip olduğu üstün özellikler yapay sinir ağlarının geleneksel tahmin ve öngörü yöntemlerinden ayrışmasını ve gerçeğe daha yakın sonuçlar üretmesini sağlamaktadır. Çalışmanın sonucunda elde edilen ikinci bulgu; OECD ülkelerinden Avustralya, Avusturya, Belçika, Kanada, Çek Cumhuriyeti, Estonya, Litvanya, Lüksemburg, Meksika, Norveç, Japonya, İspanya, İsveç, İsviçre, Türkiye ve Birleşik Krallık'ta demiryolu altyapı yatırımlarının 2019-2023 döneminde belirli yıllarda azalış gösterdiği'dir. Nitekim Covid-19 pandemisinin yarattığı ekonomik belirsizlik hükümetlerin bütçelerini yeniden gözden geçirmelerine ve altyapı projelerine ayrılan payın azalmasına sebep olduğu söylenebilir. Bu durum küresel ölçekte ulaşım altyapı yatırımlarının azalması ile sonuçlanmıştır. Fakat Belçika ve Türkiye haricinde bahsedilen diğer ülkelerde demiryolu altyapı yatırımları 2025 yılında artışa geçecektir. Öyle ki OECD ülkelerinin mevcut demiryolu ağlarını modernize etme ve çevre dostu ulaşımı sağlama hedeflerinin demiryolu altyapısına olan talepte artışa sebebiyet verecek unsurlar olduğunu söylemek mümkündür. Belçika ve Türkiye'de ise iç piyasa dinamiklerinin ve sürekli değişen uluslararası ekonomik koşulların demiryolu altyapı yatırımlarının azalmasına sebep olabilecek unsurlar oldukları söylenebilir. Çalışmada üçüncü olarak; kişi başına düşen demiryolu altyapı yatırımlarında Avustralya, Avusturya, Litvanya, Norveç ve Birleşik Krallık'ta 2025 yılında artış yaşanacağı öngörülür iken; Kanada, Finlandiya, Fransa ve Türkiye'de aynı yıl düşüş yaşanacağı tespit edilmiştir. Geniş coğrafi alanı 2025 yılında Avustralya'nın hem yeni altyapı projeleri geliştirmesine hem de mevcut hatların modernizasyonuna devam etmesine neden olabilecektir. Zaten gelişmiş demiryolu hatlarına sahip Avusturya ile Birleşik Krallık'ta ve Avrupa Birliği fonlarından yararlanan Litvanya'da yüksek altyapı modernizasyon harcamalarının olması mümkündür. Tüm bunlar bahsedilen ülkelerde kişi başına düşen demiryolu altyapı yatırımların 2025 yılında artışa geçmesine sebebiyet verebilecek unsurlardır. Uzun yıllardır gelişmiş demiryollarına sahip Kanada ve Fransa'da hükümetlerin farklı projelere yönelmeleri söz konusu olabilir iken; Türkiye'de değişen iç piyasa koşullarının altyapı

yatırımları üzerinde ciddi etkisinin bulunduğu söylenebilir. Bu kapsamda hükümetlerin yeni öncelikleri ve değişken iç piyasa koşullarının varlığı yukarıda bahsedilen ülkelerde 2025 yılında kişi başına düşen demiryolu altyapı yatırımlarının azalmasına sebebiyet verebilecek unsurlardır. Dördüncü olarak çalışmada; İsveç'te 2022 yılı sonrasında, Finlandiya'da 2023 yılı sonrasında GSYH başına düşen toplam iç ulaşım altyapı yatırımlarında sürekli azalış yaşanacağı tespit edilir iken, Norveç'te 2023 ve 2025 yıllarında keskin düşüşler olacağı öngörülmüştür. Türkiye'de 2022 yılındaki azalış sonrasında, Estonya'da ise 2022 ve 2024 yıllarında yaşanan azalış sonrasında GSYH başına düşen toplam iç ulaşım altyapı yatırımlarında 2025 yılında yükseliş olacağı tahmin edilmiştir. Nitekim İsveç, Finlandiya ve Norveç gibi İskandinav ülkelerinin zaten gelişmiş iç ulaşım altyapı yatırımlarına sahip olması hükümetlerin gelecekteki yatırımlarda temkinli davranmalarına sebebiyet verebilir. Ekonomik büyüme ve artan uluslararası ticaret Türkiye'de iç ulaşım altyapı yatırımlarının artmasına neden olabilecek unsurlar olarak değerlendirilebilir. Bu kapsamda Türkiye'de iç ulaşım altyapı yatırımlarının ekonomik koşullara bağlı olduğunu söylemek mümkündür. Bu nedenle de makroekonomik değerlerin dengede tutulması oldukça önemlidir. Son olarak ise; Avusturya, İrlanda, İtalya, Letonya, Litvanya, Lüksemburg, İsviçre, Türkiye ve Birleşik Krallık'ta 2025 yılında uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının artacağı; Avustralya, Estonya ve Norveç'te ise azalacağı öngörülmüştür. Öyle ki Avusturya, İrlanda, İtalya, Letonya, Litvanya, Lüksemburg, İsviçre, Türkiye ve Birleşik Krallık'ta Covid-19 salgını sonrasında artan hava trafiği emisyon artışına sebebiyet verebilecektir. Bu ülkeler hava trafiği yönetimini sağlamak adına uçuş rotalarını optimize edebilirler. Aynı zamanda bu ülkelerde elektrikli uçak teknolojilerine yatırım yapılması ve biyoyakıt kullanımının sağlanması havacılıktan kaynaklı CO₂ emisyonlarının artışını engelleyebilecektir. Diğer yandan Avustralya, Estonya ve Norveç'te uygulanan enerji verimliliğini arttırmaya yönelik yatırımların ve karbon dengeleme mekanizmalarının emisyon azaltımına katkı sağlayacağı söylenebilir.

3.7. Çalışmanın Kısıtlılıkları ve Gelecekle İlgili Yönelimler

Çalışmada elde edilen sonuçlara bazı kısıtlılıklar çerçevesinde ulaşıldığı unutulmamalıdır. Öyle ki öncelikle çalışmada sadece 29 adet OECD üyesi ülke seçilmiştir. İleriki çalışmalarda örneklem sayısı arttırılarak OECD üyesi ülkelerinin hepsinin analize dahil edilmesi sonuçların genellenebilirliğine katkı sunacaktır. İkincisi,

analizler için her ÷lkeye ait yalnızca dört adet deęişken seçilmiştir. Bu deęişkenler demiryolları ile iç ulaşım altyapı yatırımlarına ve havacılık sığınaklarından kaynaklanan CO₂ emisyonlarına ilişkin deęişkenlerdir. Özellikle ileriki çalışmalarda altyapı modernizasyon harcamaları, hava trafięi ve iç piyasa koşullarına ilişkin makroekonomik deęişkenlerin analize dahil edilmesi daha kapsamlı politika çıkarımlarının yapılabilmesine katkı sunacaktır. Üçüncü kısıt; çalışmada uzun dönemli bir öngörüden ziyade 2025 yılı için bir projeksiyon sunulmuş olmasıdır. Özellikle OECD ÷lkeleri içerisinde yer alan AB üyesi ÷lkelerin Avrupa Yeşil Mutabakatı kapsamında 2050 yılına kadar sera gazı emisyonlarını sıfırlama hedefleri düşünüldüğünde öngörülerin ilgili yıla kadar gerçekleştirilmesinin daha geniş bir projeksiyon sunacağı düşünülmektedir. Son olarak ise; öngörü modellerinin oluşturulmasında yalnızca yapay sinir ağı türlerinden çok katmanlı ağlar tercih edilmiştir. Bu kapsamda ileride gerçekleştirilecek çalışmalarda çoklu doğrusal regresyon gibi geleneksel bir tahmin yönteminin de analize dahil edilerek model performanslarının karşılaştırılması faydalı olacaktır.

4. BÖLÜM

PANEL REGRESYON ANALİZİ

ÖZET

Günümüzde uluslararası ticaretin can damarlarından bir tanesi hızlı ve güvenilir bir lojistik sistemdir. Bu lojistik sistem içerisinde malların ülkeler arasında yer değiştirmesini sağlayan taşımacılık faaliyetleri ise yadsınamaz bir öneme sahiptir. Fakat taşımacılık faaliyetinin etkin bir şekilde gerçekleşerek katma değer yaratabilmesi ulaşım altyapısına yapılacak yatırımlara bağlıdır. Nitekim ulaşım altyapısına yapılacak yatırımlar lojistik kapasitesinde artışa, üretkenliğe ve verimliliğe neden olacaktır. Nihai olarak ise; ulaşım altyapısına yapılan yatırımların ekonomik büyümeye yol açması beklenmektedir. Bu kapsamda bu çalışmanın amacı, demiryolu altyapı yatırımlarının, kişi başına düşen demiryolu altyapı yatırımlarının, GSYH başına düşen toplam iç ulaşım altyapı yatırımlarının ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının ekonomik büyümeye etkisini panel veri analiz yöntemleri ile ortaya koymaktır. Bu doğrultuda OECD üyesi 29 ülkenin 2010-2019 dönemini kapsayan yıllık verileri STATA 16 paket programında analize tabi tutulmuştur. Panel veri modelinin belirlenmesi amacı öncelikle klasik modelin geçerliliği F testi ve Breusch-Pagan LM testi kullanılarak sınanmıştır. Klasik modelin uygun olmadığından belirlenmesinin ardından sabit etkiler ile tesadüfi etkiler modeli arasında seçim yapabilmek için Hausman Testi kullanılmış ve sabit etkiler modelinin uygunluğuna karar verilmiştir. Sabit etkiler modelinde değişen varyans varsayımından sapmaların belirlenmesi için Değiştirilmiş Wald Testi, otokorelasyon sorununun tespiti için Baltagi Wu'nun Yerel En İyi Değişmez Testleri ve yatay kesit bağımlılığının sınanması için Pesaran CD Testi kullanılmıştır. Yapılan testler sonucunda modelde değişen varyans, otokorelasyon ve yatay kesit bağımlılığı tespit edildiği için Driscoll-Kraay tahmincisi kullanılarak regresyon analizi gerçekleştirilmiştir. Çalışmanın sonucunda; demiryolu altyapı yatırımı ve kişi başına düşen demiryolu altyapı yatırımının GSYH üzerindeki etkisinin istatistiki olarak anlamsız olduğu tespit edilir iken GSYH başına düşen toplam iç ulaşım altyapı yatırımı ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının GSYH üzerindeki etkisinin istatistiki olarak anlamlı olduğu belirlenmiştir.

Anahtar Sözcükler: Panel Regresyon Analizi, Driscoll-Kraay Tahmincisi, OECD, Ekonomik Büyüme, Taşımacılık.



ABSTRACT

One of the lifeblood of international trade today is a fast and reliable logistics system. Transportation activities that enable the movement of goods between countries within this logistics system have an undeniable importance. However, the ability of transportation activities to be carried out effectively and create added value depends on investments in transportation infrastructure. Indeed, investments in transportation infrastructure will lead to an increase in logistics capacity, productivity, and efficiency. Ultimately, investments in transportation infrastructure are expected to lead to economic growth. In this context, the aim of this study is to reveal the effects of railway infrastructure investments, railway infrastructure investments per capita, total domestic transportation infrastructure investments per GDP, and the share of CO₂ emissions from international aviation bunkers in total CO₂ emissions on economic growth using panel data analysis methods. In this context, annual data of 29 OECD member countries covering the period 2010-2019 were analysed in the STATA 16 package program. In order to determine the panel data model, firstly the validity of the classical model was tested using the F test and the Breusch-Pagan LM test. After determining that the classical model was not suitable, the Hausman Test was used to choose between the fixed effects and random effects models and the suitability of the fixed effects model was decided. The modified Wald test was used to determine deviations from the heteroscedasticity assumption in the fixed effects model, Baltagi Wu's locally best invariant tests were used to detect the autocorrelation, and the Pesaran CD test was used to test the cross-sectional dependence. As a result of the tests, regression analysis was performed using the Driscoll-Kraay estimator since heteroscedasticity, autocorrelation, and cross-sectional dependence were detected in the model. According to findings of the study, it was determined that the effect of railway infrastructure investment and railway infrastructure investment per capita on GDP was statistically insignificant, while the effect of total domestic transportation infrastructure investment per GDP and the share of CO₂ emissions from international aviation bunkers in total CO₂ emissions on GDP was statistically significant.

Keywords: Panel Regression Analysis, Driscoll-Kraay Estimator, OECD, Economic Growth, Transportation.

GİRİŞ

Günümüzde içerisinde bulunduğumuz küresel dünya düzeninin bir parçası olan liberal ekonomik sistemin bir sonucu olarak uluslararası ticaret çok yüksek bir hız ile büyümektedir. Uluslararası ticaretin bu denli hızlı büyümesi, ülkelerin hızlı ve güvenilir bir lojistik sistem kurmalarının önemini de arttırmaktadır. Hızlı ve güvenilir bir lojistik sistemde merkezi öneme sahip faaliyetlerden biri ise taşımacılıktır. Çünkü ancak etkin bir taşımacılık faaliyeti sonucunda bir ülkede üretilen ürünlerin son tüketim noktasına beklentileri karşılayacak şekilde zamanında ulaşımın sağlanması ile uluslararası ticaretten pay elde edilebilecektir. Bir ülkede taşımacılık faaliyetinin etkin bir şekilde gerçekleştirilebilmesi ve uluslararası ticarete söz sahibi olunabilmesi için ise gelişmiş bir ulaşım altyapısına ihtiyaç duyulmaktadır. Bu doğrultuda ulaşım altyapısına yapılacak yatırımların etkin bir taşımacılık faaliyetinin gerçekleştirilmesine ve dolayısı ile de ülkelerin iç ve dış ticaretini geliştirerek ekonomik büyümeye yol açması beklenmektedir.

Bu çalışma literatürde ulaşım altyapısına yapılan yatırımların ekonomik büyüme üzerindeki etkisini inceleyen çalışmalardan hem değişken hem de örneklem seçimi bağlamında farklılaşmaktadır. Öncelikle literatürde bu çalışmada seçilen dört adet bağımsız değişkenin birlikte seçildiği ve GYSH bağımlı değişkeni üzerindeki etkisinin incelendiği bir çalışmaya rastlanmamıştır. Nitekim ilgili literatür incelendiğinde özellikle son yıllarda ulaşım altyapı harcamalarına ek olarak bilgi iletişim teknolojileri, çevre kirliliği, gayrisafi sabit sermaye oluşumu, işgücü ve ticari açıklık değişkenlerinin ekonomik büyüme üzerindeki etkisini inceleyen çalışmalara (Badalyan et al., 2014; Hayaloğlu, 2015; Gherghina et al., 2018; Kabaklarlı et al., 2018; Wang et al., 2020; Samir & Mefteh, 2020; Pradhan et al., 2021; Şen et al., 2023) rastlanmıştır. Bu çalışmalardan ise yalnızca iki tanesinde (Hayaloğlu, 2015; Kabaklarlı et al., 2018) OECD ülkeleri örneklem olarak seçilmiştir. Diğer çalışmalarda ise Avrupa Birliği üyesi ülkelerin yanı sıra G-20 ülkeleri ile BRICS ülkelerinin örneklem olarak seçildiği görülmüştür. Bu çalışmada ise literatürdeki çalışmalardan farklı olarak OECD ülkelerinde demiryolu altyapı yatırımlarının yanı sıra iç ulaşım altyapı yatırımları ve uluslararası havacılık sığınaklarının sebep olduğu CO₂ emisyonlarının ekonomik büyüme üzerindeki etkisine odaklanılmıştır. Bu kapsamda bu çalışmanın amacı, demiryolu altyapı yatırımlarının, kişi başına düşen demiryolu altyapı yatırımlarının, GSYH başına düşen toplam iç ulaşım altyapı yatırımlarının ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının ekonomik büyümeye

etkisini panel veri analiz yöntemleri ile analiz etmektir. Bu amaç doğrultusunda OECD üyesi 29 ülkenin 2010-2019 dönemini kapsayan yıllık verilerinin doğal logaritması alındıktan sonra STATA 16 paket programında analize tabi tutulmuştur. Çalışmada öncelikle panel veri modeli belirlenmiştir. Öyle ki panel veri modelinin belirlenmesi için klasik modelin geçerliliği ilk olarak F testi ile sonrasında Breusch-Pagan LM testi ile sınanmıştır. Yapılan testler sonucunda klasik modelin uygun olmadığı belirlenmesinin ardından sabit etkiler modeli ile tesadüfi etkiler modeli arasında seçim yapabilmek için Hausman Testi kullanılmıştır. Hausman Testi sonucunda sabit etkiler modelinin uygun olduğuna karar verilmiştir. Ardından sabit etkiler modelinde değişen varyans varsayımından sapmaların belirlenmesi için Değiştirilmiş Wald Testi, otokorelasyon sorununun tespiti için Baltagi Wu'nun Yerel En İyi Değişmez Testleri ve yatay kesit bağımlılığının sınanması için Pesaran CD Testi kullanılmıştır. Elde edilen sonuçlara göre sabit etkiler modelinde değişen varyans, otokorelasyon ve yatay kesit bağımlılığı tespit edildiği için dirençli bir tahminci olan Driscoll-Kraay kullanılarak regresyon analizi gerçekleştirilmiştir.

Literatürdeki çalışmalardan değişken ve örneklem seçimi bağlamında farklılaşan bu çalışmada elde edilen panel regresyon analizi sonuçları da dikkat çekicidir. Nitekim çalışmanın sonucunda; yüksek kentleşme ve yüksek ihracata sahip ülkelerde demiryolu altyapısına ilişkin iyileştirmelerin ekonomik büyüme üzerinde etkili olduğu sonucuna ulaşan Zheng et al., (2024)'ün aksine bu çalışmada demiryolu altyapı yatırımı ve kişi başına düşen demiryolu altyapı yatırımının GSYH üzerindeki etkisinin istatistiki olarak anlamsız olduğu tespit edilmiştir. Ayrıca çalışmada GSYH başına düşen toplam iç ulaşım altyapı yatırımı ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının GSYH üzerindeki etkisinin istatistiki olarak anlamlı olduğu belirlenmiştir. Fakat literatürde ulaşım altyapı yatırımlarının ekonomik büyüme üzerinde pozitif etkisi olduğunu saptayan çalışmaların (Hayaloğlu, 2015; Gherghina et al., 2018; Kabaklarlı et al., 2018; Kara & Cığırlioğlu, 2018; Wang et al., 2020; Samir & Mefteh, 2020; Pradhan et al., 2021) aksine bu çalışmada GSYH başına düşen toplam iç ulaşım altyapı yatırımında yaşanan %1'lik artışın GSYH'yı %0.115 azalttığı saptanmıştır. Uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payında yaşanan %1'lik bir artışın ise GSYH'yı %0.544 arttırdığı saptanmıştır. Bu doğrultuda literatürdeki çalışmalardan değişken, örneklem seçimi ve elde edilen sonuçlar bağlamında farklılaşan

bu çalışmanın literatüre katkı sağlayacağı ve politika belirleyicilere yol göstereceği düşünülmektedir.

4.1. Literatür Taraması

Ülkelerdeki ulaşım altyapısının ekonomik büyüme üzerindeki etkisini inceleyen çalışmalardan bazıları Tablo 1.1’de yer almaktadır. Tablo 4.1.’de görüldüğü üzere literatürde genellikle OECD, AB, G-20 ve BRICS ülkeleri örneklem olarak seçilmiş ve farklı panel veri modelleri kullanılarak analizler gerçekleştirilmiştir.

Tablo 4.1. Ulaşım Altyapısının Ekonomik Büyüme Üzerindeki Etkisini İnceleyen Çalışmalar

Yazar-Yıl	Çalışmanın Başlığı	Veriler	Yöntem	Bulgular
(Badalyan et al., 2014).	Transport infrastructure and economic growth: panel data approach for Armenia, Georgia and Turkey.	Ermenistan, Türkiye ve Gürcistan’ın 1982-2010 dönemine ait GSYH, karayolu ve demiryolu taşımacılığı (yük ve yolcu), karayolu ve demiryolu ağ uzunlukları ve gayrisafi yurtiçi sermaye oluşumu.	Vektör Hata Düzeltme Modeli (VECM).	Kısa dönemde gayrisafi yurtiçi sermaye oluşumu ile karayolu ve demiryolu yük taşımacılığının ekonomik büyüme üzerinde istatistiksel olarak pozitif ve anlamlı bir etkiye sahip olduğu saptanmıştır. Büyüme ve altyapı yatırımı ile taşınan karayolu ve demiryolu yolcuları ile altyapı yatırımları arasında hem kısa hem de uzun vadede çift yönlü nedensellik olduğu tespit edilmiştir.
(Hayaloğlu, 2015).	The impact of developments in the logistics sector on economic growth: the case of OECD countries.	1994-2011 dönemi için 32 OECD üyesi ülkeye ait kullanılan lojistik sektörü değişkenleri: Demiryolu taşımacılığı, havayolu taşımacılığı, karayolu taşımacılığı, yurtiçi taşımacılık altyapıları, internet abone sayısı ve telefon hatlarıdır.	Panel veri analizi.	İç ulaşım altyapı yatırımlarının ekonomik büyüme üzerinde pozitif etkisi olduğu saptanmıştır.

(Gherghina et al., 2018).	Empirical evidence from EU-28 countries on resilient transport infrastructure systems and sustainable economic growth.	Avrupa Birliği (AB-28) ülkelerinin 1990-2016 yılları arasında yer alan verileri kullanılmıştır. Bunlar: kişi başına düşen GSYH, ulaştırma altyapısına ilişkin çeşitli önlemler, ulaştırma altyapı yatırımları, ulaştırma kirliliği ve ülke düzeyindeki kontroller.	Sabit ve dinamik etkiler modeli. Granger nedensellik testi.	İç su yolu hariç bütün ulaştırma altyapı yatırımlarının ekonomik büyümeyi olumlu etkilediği belirlenmiştir. Ayrıca uzun vadede demiryolu altyapısına yapılan yatırımlar ile kişi başına düşen GSYH arasında iki yönlü bir nedensellik tespit edilmiştir. Her türlü ulaşımdan kaynaklanan CO ₂ emisyonlarının kişi başına düşen GSYH üzerinde olumsuz etkileri saptanmıştır. Aynı zamanda kısa dönemde demiryolundan kaynaklı CO ₂ emisyonları ile kişi başına düşen GSYH arasında çift yönlü; karayolu ile uluslararası havacılık ile kişi başına düşen GSYH arasında tek yönlü bir nedensellik tespit edilmiştir.
(Kabaklı et al., 2018).	Ulaştırma altyapı yatırımlarının ekonomik büyümeye katkısı: Seçilmiş ülkeler için panel eşbütünleşme analizi	1995-2015 yılları için 17 OECD üyesi ülke ve Rusya'ya ait değişkenler kullanılmıştır: Kişi başına düşen GSYH, işgücüne katılım oranı, gayrisafi sabit sermaye oluşumu, toplam ulaşım altyapı yatırımı ve ulaştırma altyapı yatırımları.	Panel Eşbütünleşme ve Ortak İlişkili Etkiler Havuzlanmış (CCEP) Tahmincisi.	Ulaştırma altyapı harcamaları ile büyüme arasında pozitif ve anlamlı bir ilişki bulunduğu tespit edilmiştir.
(Kara & Cığırlioğlu, 2018).	Türkiye ekonomisinde ulaşım altyapısının	1988-2015 dönemine ait kişi başına GSHY, gayrisafi sabit sermaye yatırımı,	Vektör Otoregresyon (VAR) analizine dayalı Johansen	Türkiye'de ulaşım altyapısındaki değişimin uzun dönemde ekonomik

	ekonomik büyümeye etkisi.	işgücü, yol uzunlukları ve patent değişkenleri kullanılmıştır.	Eşbütünleşme Testi.	büyümeyi pozitif etkilediği saptanmıştır.
(Wang et al., 2020).	Railway and road infrastructure in the Belt and Road Initiative countries: Estimating the impact of transport infrastructure on economic Growth.	Çin'in Bir Kuşak, Bir Yol Projesi kapsamında olan 65 ülkenin 2007-2016 yılları arasındaki ekonomik büyüme, ulaşım altyapısı, işgücü, kentleşme düzeyi, ticari açıklık ve fiziksel sermaye değişkenleri kullanılmıştır.	Statik ve dinamik panel veri modeli.	Ulaşım altyapısının ekonomik büyümeyi kolaylaştırdığı belirlenmiştir.
(Samir & Mefteh, 2020).	Empirical analysis of the dynamic relationships between transport, ICT and FDI in 63 countries.	2000-2016 dönemi için farklı gelir düzeyine sahip 63 seçilmiştir. Seçilen değişkenler: Kişi başına düşen GSYH, doğrudan yabancı yatırım, ulaştırma altyapısı, bilgi ve iletişim teknolojileri, ticari açıklık, kentleşme, finansal gelişme, sermaye stoğu ve enflasyon oranıdır.	Arellano ve Bond Genelleştirilmiş Momentler Tahmincisi.	Ulaştırma altyapısına yapılan yatırımların uluslararası ticareti artırarak ülkelerin ekonomik açıklığını güçlendirdiği ve ekonomik büyümeyi arttırdığı tespit edilmiştir.
(Pradhan et al., 2021).	Urbanization, transportation infrastructure, ICT, and economic growth: A temporal causal analysis.	G-20 ülkelerinin 1961-2016 dönemlerine ait kentleşme, ulaşım altyapısı, bilgi ve iletişim teknolojileri alt yapısı ile ekonomik büyüme verileri kullanılmıştır.	Vektör Hata Düzeltme Modeli.	Akıllı ulaşım sistemlerinin uzun vadeli ekonomik büyümeye katkı sağladığı vurgulanmıştır.
(Apurv & Uzma, 2021).	The impact of infrastructure investment and development on	Brezilya, Rusya, Hindistan, Çin ve Güney Afrika (BRICS) ülkelerinin	En Küçük Kareler Yöntemi.	Brezilya ve Güney Afrika'da ulaşım altyapısının ekonomik büyüme ile önemli bir

	economic growth on BRICS.	1980-2017 yılları arasındaki panel veri seti kullanılmıştır.		ilişkisinin bulunmadığı, Çin’de ulaşım altyapı yatırımı ile ekonomik büyüme arasında negatif bir ilişki bulunduğu fakat Rusya’da enerji ve ulaşım altyapı yatırımlarının ekonomik büyümeye yol açtığı tespit edilmiştir.
(Şen et al., 2023).	Altyapı ve iktisadi büyüme ilişkisi üzerine ekonometrik bir analiz.	Ulaşım modeli için 12; telekomünikasyon modeli için 38; enerji kullanımı modeli için 35; elektrik tüketimi modeli için ise 34 ülkeye ilişkin 2011-2020 dönemine ait veriler kullanılmıştır.	Genelleştirilmiş Momentler Yöntemi tahmincisi.	Telekomünikasyon ve enerji altyapısının iktisadi büyüme üzerinde etkili olduğu fakat ulaşım altyapısının iktisadi büyüme üzerinde etkili olmadığı belirlenmiştir.
(Zheng et al., 2024).	Relative improvements between roads and railways and economic performance: A panel data analysis.	1980-2018 yıllarını kapsayan, 50 ülkenin ve 9 farklı değişkenin yer aldığı bir panel veri seti kullanılmıştır.	Sabit etkiler panel doğrusal regresyon.	Düşük kentleşme ve düşük ihracata sahip olan ülkelerde karayolu altyapısındaki iyileştirmelerin demiryollarındaki iyileştirmelere kıyasla daha fazla ekonomik etki yarattığı, yüksek kentleşme ve yüksek ihracata sahip ülkelerde ise demiryolu altyapısına ilişkin iyileştirmelerin önem kazandığı vurgulanmıştır.

4.2. Lojistik Kavramı ve Gelişimi

Lojistik (logistics), Fransızca “kışla” ve “arz etmek” anlamlarına gelen “logistique” ve Yunanca “hesaplama yeteneği” veya “hesap bilimi” anlamına gelen “logistikos” kelimelerinden türemiş bir kavramdır. Lojistik (logistics) kavramı esasen “logic” ve “statistics” kelimelerinin bileşiminden meydana gelmiştir (Russell, 2000: 14) Bu kelimelerin Türkçe karşılığı ise “mantıklı istatistik (hesap)” olarak karşımıza çıkmaktadır. Bazı kaynaklar ise lojistik kavramının Fransızca ürün depolamak veya


saklamak anlamına gelen “loger” kelimesinden türediğine işaret etmektedir (Voortman, 2004: 7) Bu doğrultuda lojistik kavramının kökeninin Fransızca olduğu söylenebilir (Magee et al., 1985: 2).

Lojistik kavramı, uzun zaman boyunca literatürde askeri kökenli bir kelime olarak yer almıştır (Magee et al., 1985: 2; Mangan & Lalwani, 2016: 4; Long, 2019: 20). Öyle ki lojistik kavramı ilk defa 1905 yılında askerlerin ve onlara ait malzemelerin taşınması, tedarik edilmesi ve bakım faaliyetlerine ilişkin tüm işleri tanımlamak üzere kullanılmıştır (Ballou, 2007: 333). Bu kapsamda lojistik, Fransızca’da birliklerin taşınması veya tedarik edilmesi anlamlarına gelen askeri bir terim olarak nitelendirilmiştir (Magee et al., 1985: 2).

Lojistik kavramı 1950’li yıllara kadar askeri bir terim olarak düşünülmüştür (Ballou, 2007: 333). Bu nedenle lojistik kavramı 1950’li yıllara kadar işletmeler tarafından bilinmemekte ve lojistik faaliyetler ayrı ayrı yürütülmekte idi. 1950-1960 dönemlerinde ise özellikle pazarlama yaklaşımının gelişmesi ile lojistik kavramı gündeme gelmeye başlamıştır (Farris, 1997: 46; Orhan, 2014: 17). Bu kapsamda 1960-2000 yılları arasında lojistik kavramının işletmeler açısından ifade ettiği anlamda büyük değişimler yaşandığı söylenebilir.

Lojistik kavramının 1960-2000 yılları arasındaki gelişimini gösteren Şekil 4.1’de görüldüğü üzere; 1960’lı yıllarda lojistik faaliyetler ayrı ayrı ele alınmakta idi. 1970’li yıllarda ise modern lojistik kavramının temelleri atılmış (Orhan, 2014: 17) ve lojistik kavramı ilk kez iş yaşamında bu dönemde kullanılmıştır (Voortman, 2004: 7). 1960’larda tek tek alınan lojistik faaliyetler 1980’li yıllardan itibaren malzeme ve ekipman yönetimi ile fiziksel dağıtım olarak bütünleşme sürecine girmiştir (Hesse & Rodrigue, 2004: 175). Nispeten bütünleşme sürecinin yaşandığı bu yıllarda fiziksel dağıtım ve lojistik eşanamlı terimler olarak kullanılmıştır (Ballou, 2007: 335). 1990’lı yıllarda malzeme ve ekipman yönetimi ile fiziksel dağıtımın içerdiği tüm faaliyetler “lojistik” kavramı altında bütünleşmiştir. 2000’li yıllarda ise bilgi teknolojilerinin oynadığı etkin rolünde etkisi ile lojistik kavramından daha kapsamlı bir kavram olan “tedarik zinciri” kavramı ortaya çıkmıştır (Hesse & Rodrigue, 2004, 175). Artık günümüzde lojistik, tedarik zincirinin bir alt kümesi olarak görülmektedir (Ballou, 2007: 340; Mangan & Lalwani, 2016: 16). Kısacası, lojistik tedarik zinciri yönetiminin bir parçasıdır. Bunun nedeni tedarik zincirinin malzeme akışını yani lojistik faaliyetleri de içeren bir yapıda olmasıdır. Fakat tedarik zinciri, lojistik kavramı gibi sadece malların bir yerden başka bir yere taşınması

ile sınırlı bir kavram değildir. Tedarik zinciri, malların asıl kaynağından (hammaddelerin topraktan çıkarıldığı yerden) tüketileceği yere kadar olan hareketini ifade etmektedir. Cooper et al., 1997: 2) tedarik zinciri yönetimini “Müşteriler için ürünler, hizmetler ve bilgiler sağlayan son kullanıcıdan orijinal tedarikçilere kadar tüm iş süreçlerinin entegrasyonu” şeklinde tanımlamışlardır. Bu kapsamda tedarik zinciri yönetimini daha yüksek karmaşıklığa sahip bir lojistik olarak düşünmek doğru olacaktır (Long, 2019: 6). Özetle, 1960’lı yıllardan günümüze kadar geçen süreç incelendiğinde askeri kökenli bir kavram olan ve bir zamanlar ordulara malzeme akışının sağlanması ile ilişkilendirilen lojistik kavramının yıllar içerisinde kişiler ve kurumlar açısından ifade ettiği anlamda büyük değişiklikler yaşandığı aşikardır. Bugün ise lojistik kavramı, tedarik zinciri yönetimi ile bir arada anılmaya başlamıştır.



Şekil 4.1. Lojistik Kavramının Gelişimi (Hesse & Rodrigue, 2004, 175).

Lojistik kavramının geçirdiği evrim dikkate alındığında günümüzde lojistiğin tek bir tanımının bulunduğunu söylemek mümkün değildir. Hem lojistik kavramının ifade ettiği anlamda yıllar içerisinde meydana gelen değişim hem de günümüzde lojistiğin oldukça geniş bir çalışma alanına sahip olması bu kavramın tek bir tanımının yapılmasını imkânsız hale getirmektedir. Bu doğrultuda geçmişten günümüze kadar çeşitli kurumlar ve araştırmacılar lojistiğe farklı açılardan yaklaşmışlar ve lojistiğin tanımını yapmışlardır. Bovet (1991: 13) lojistiği “Göndericiden müşteriye ürün ve bilgi akışlarının yönetimi”

şeklinde tanımlar iken Voortman (2004: 1) lojistiği “Bir malın veya hizmetin ilk müşteri siparişinden, o malın müşteri tarafından nihai tüketimine kadar geçen süreç” şeklinde tanımlamıştır. Waters (2021: 5) lojistiğin tanımını şu şekilde yapmıştır: “Lojistik, malzemelerin tedarikçilerden kuruluşlara, kuruluş içerisindeki operasyonlar yoluyla da müşterilere akışından sorumlu fonksiyondur”. Kısacası lojistik, kaynağından nihai tüketiciye kadar olan tüm malzeme akışını yönetme sanatıdır (Magee et al., 1985: 2).

Günümüzde kabul gören lojistik tanımlarından biri ise Lojistik Yönetimi Konseyi (The Council of Logistics Management) tarafından yapılan tanımdır. Lojistik Yönetimi Konseyi lojistiği, "Müşteri ihtiyaçlarını karşılamak amacıyla malların, hizmetlerin ve ilgili bilgilerin çıkış noktasından tüketim noktasına kadar verimli, etkin akışını ve depolanmasını planlama, uygulama ve kontrol etme süreci" olarak tanımlamaktadır (<https://cscmp.org>, erişim tarihi: 26.03.2023). Lojistik ile ilgili yapılan farklı tanımlardan da anlaşılacağı üzere lojistik olmadan malların nihai tüketicilere ulaştırılması mümkün olmazdı.

4.3. Ulaştırma-Taşıma, Lojistik ve Ekonomi İlişkisi

4.3.1. Ulaştırma-taşıma ve lojistik ilişkisi

Ulaştırma kavramı, belirli bir amaca yönelik olarak eşyaların ve insanların yer değiştirmesini ifade eder iken taşıma kavramı ise dar anlamda, malzemelerin ve insanların coğrafi açıdan yer değiştirmesini ifade etmektedir (Erturgut, 2016: 115). Taşımacılık faaliyeti geniş anlamda; üretilen malların müşteri ihtiyaçlarını gidermek üzere ihtiyaç duyulan bölgelere zamanında ulaştırılmasıdır (Koban & Keser, 2021: 132). Lojistik ise malzemeleri ihtiyaç duyulduğu yere ulaştırma işi olarak tanımlanmaktadır (Long 2019: 3). İşte bahsedilen malzemeleri ihtiyaç duyuldukları yerlere ulaştırmak için tüm lojistik faaliyetler içerisinde en önemlisi taşımacılık faaliyetleridir (Tseng et al., 2005: 1660; Long, 2019: 19; Koban & Keser, 2021: 132).

Taşımacılık faaliyetleri lojistik sistem içerisinde her açıdan merkezi öneme sahiptir. Çünkü taşımacılığın lojistik sistem içerisinde oynadığı rol, malların taşınmasından daha karmaşıktır. Öyle ki taşımacılık, lojistik süreçlerin çeşitli bölümlerinde karşımıza çıkmakta ve lojistik yönetimi faaliyetlerini gerçekleştirmek için taşımacılık faaliyetlerine ihtiyaç duyulmaktadır (Daniela & Oradea, 2014: 37). Aynı zamanda da lojistik maliyetlerin yaklaşık üçte biri ile üçte ikisini taşımacılık faaliyetleri oluşturmaktadır. O halde daha iyi bir taşıma sisteminin varlığı daha iyi lojistik verimlilik sağlayabilir ve bu

da işletme maliyetlerinin azalmasına ve hizmet kalitesi artışına sebep olabilir. İyi tasarlanmış bir lojistik sistem ise hem işletmelerin hem de devletin rekabet gücünü arttırabilir (Tseng et al., 2005: 1660). Kısacası; taşımacılık faaliyetlerinde elde edilecek üstünlük lojistik sektöründe rekabet edilebilirliği, lojistik sektöründe elde edilecek üstünlük ise ülkelerin rekabet gücünü arttıracaktır.

Taşımacılığın lojistik sistem içinde sahip olduğu kritik önem özellikle ülke içi ticaretten uluslararası ticarete geçildiğinde daha da belirgin hale gelmektedir. Çünkü uluslararası ticarete taşımacılık, ulusal sınırları aşmakta ve bu da yurtiçi taşımacılığa göre bazı farklılık ve zorlukları beraberinde getirmektedir. Taşımacılıkla ilgili yasa ve yönetmelik farklılıkları, ekonomik politika ve para birimi farklılıkları, piyasaların yapısal özelliklerinin farklılığı, karşılaşılan risklerin farklılığı (Koban & Keser, 2021: 12-13), dokümantasyon fazlalığı ve uzun taşıma mesafelerinin varlığı uluslararası taşımacılığı yurtiçi taşımacılıktan ayıran farklılıklarından bazılarıdır (Long, 2019: 19-20). İşte özellikle firmaları müşterilerinden ayıran bu uzun mesafelerin varlığında taşımacılık, küresel lojistik çabanın kritik bir unsuru olarak karşımıza çıkmakta ve taşımanın hem ucuz hem de hızlı taşıma sistemleri ile yapılması önem kazanmaktadır. Güvenilir, ucuz ve hızlı taşımacılığın gerçekleştirilebilmesi için ise gelişmiş bir ulaşım altyapısına olan ihtiyaç günden güne artmaktadır.

Günümüzde sosyal, kültürel ve ekonomik faaliyetler dolayısı ile taşıma hizmetlerine karşı yoğun bir talep oluşmaktadır. Taşıma hizmetlerine olan talebe bağlı olarak da ulaşım altyapısına olan ihtiyaç artmaktadır (Erturgut, 2021: 114). Çünkü gelişmiş bir ulaşım altyapısına sahip olunmadan lojistik avantajlardan yararlanmak olası değildir (Tseng et al., 2005: 1660). Bu kapsamda planlı ve düzenli bir ulaşım ağının oluşturulması ülkelerin lojistik avantajlardan daha fazla yararlanması açısından kritik öneme sahiptir.

4.3.2. Ekonomi ve lojistik ilişkisi

Ekonomi, oldukça eski bir bilim dalıdır. Öyle ki MÖ 380 ila 350 yılları arasında hem Platon hem de Aristoteles ekonomi bilimi hakkında yazılar yazmışlardır. Lojistik ve ulaştırmanın akademik çalışmaları da yeni değildir. Ulaştırma ile ilgili yapılan çalışmalar 1850’lerde Amerika’da Yale Üniversitesi rektörü ekonomist Henry Adams’ın “Ulaştırma Ekonomisi” dersi verdiği yıllara kadar dayanmaktadır. Bu kapsamda geçmişten

günümüze kadar ekonomistlerin herhangi bir ekonominin büyümesi ve gelişmesini inceler iken ulaşım kavramı ile ilgilenmesi de tesadüf değildir (Farris, 1997: 42).


Geçmişte olduğu gibi bugün de ulaştırma-taşıma ve lojistik, ülke ekonomilerinin önemli bir bileşenidir. En yalın hali ile ekonomik göstergeler, bir ülkenin gelişmişlik ve kalkınmışlık düzeyini gösteren en önemli yapı taşları iken, lojistik ise günümüzde ekonomik göstergelerin değişiminde önemli role sahip bir aktördür. Lojistik, üstlenmiş olduğu rol ile ülke ekonomisine farklı yönlerden değer ve katkı sağlamaktadır (Erkan, 2014: 48).

Ülkelerin ekonomik göstergelerinde meydana gelecek değişimlerde önemli bir yere sahip olan lojistik faaliyetler içerisinde anahtar faktör ulaşım"dır. Ulaşım altyapısının gelişmesi ülkelerin dünya ekonomisi ile bütünleşmesinde yadsınamaz bir yere sahiptir (Hayaloğlu, 2015: 523). Çünkü ulaşım hizmetine olan talep ve buna bağlı olarak da ulaşım altyapısına olan ihtiyaç gün geçtikçe artmaktadır. Bu denli yoğun bir talebin olduğu bir dönemde zayıf bir ulaşım altyapısına sahip olunması ülkelerin ekonomik anlamda gelişmesini kısıtlayabilmektedir (Murphy & Wood, 2015: 18-19). Bunun nedeni ise; bir ülkede mal ve hizmetlerin dağıtılmasının, iç ve dış ticaretin geliştirilmesinin ancak düzenli bir ulaşım ağı ile mümkün olmasıdır (Akgüngör & Demirel, 2004: 424). Öyle ki, bir ülkede üretilen ürünlerin son tüketim noktasına ve nihai müşterilere zamanında, istenilen koşullarda ve beklentileri karşılayacak şekilde ulaşımı sağlanamaz ise o ürünün ekonomik değeri de kalmamaktadır (Koban & Keser, 2021: 148). Öyle ise; bir ülkede iyi tasarlanmış ulaştırma sistemlerinin ekonomik faaliyetlerin canlanmasında etkin rol oynayan bir araç olduğunu söylemek mümkündür.

Ulaştırma ve taşıma sektörünün iyi tasarlanmadığı bir ülkede en önemli ekonomik faaliyetlerden biri olan dış ticarete olumsuz gelişmelerin yaşanılması kaçınılmazdır. Çünkü küresel dünya düzeni içerisinde taşımacılık, depolama ve tedarik zinciri yönetimi başta olmak üzere; lojistik imkanlar ülkelerin dış ticaretinde her zamankinden daha fazla belirleyici olmaya başlamıştır (Akçetin et al., 2013: 74-75). Öyle ki günümüzde iyi tasarlanmış bir dış ticaret lojistiğinin varlığı ülkelerin küresel dış ticareti kontrol etmelerinde ve bu ticaretten pay almalarında ayrı bir öneme sahip olmaktadır (Kara et al., 2009: 71). Aslında günümüzde lojistik sektörünün uluslararası ticaretin can damarı olduğu da söylenebilir (Küçük, 2022: 65). Çünkü bir ülkede verimli dış ticaret lojistiğinin varlığı ülkenin ihracatını arttırmada kilit öneme sahiptir (Devlin & Yee, 2005: 436). Artık güçlü bir lojistik organizasyonu bulunmayan ülkelerin gerçek anlamda küresel aktörlerin

ihtiyalarına cevap verebilen ihracatı ekonomilere sahip olmaları da mmkn deėildir (Saidi & Hammami, 2011: 485-486). O halde bir lkenin lojistik kalitesinin uluslararası ticaretin de belirleyicisi olduėunu sylemek yanlış olmayacaktır. Bu kapsamda iyi tasarlanmış ulařım sistemlerinin eksikliğinde ve taşımacılık sektörne yapılan yatırımların yetersiz kalması halinde öncelikle lojistik sektörnde kayıplar yaşanacak, ardından yaşanan kayıpların etkileri diėer sektörler üzerinde hissedilecek, son olarak ise özellikle dıř ticarete oluřacak olumsuz gelişmeler ekonomik göstergeleri de olumsuz yönde etkileyecektir (Koban & Keser, 2021: 149).

Lojistiėin uluslararası ticaretin can damarı olduėu ve dıř ticaretin de lkelerin ekonomik göstergeleri üzerindeki etkisi dikkate alındığında lojistik altyapısına yapılacak yatırımların önemi açıka görlmektedir. Özellikle günmzde küresel dünya düzeninin etkisi ile liberalleşen dıř ticaret, uluslararası ticaret hacminin akıl almaz derecede büyümesine sebep olmakta, artan ticaret hacmi ise lkelerin lojistik kapasitelerini arttırmalarını zorunlu hale getirmektedir (Gani, 2017: 279). Lojistik kapasitesinin, verimliliėin, güvenilirliėin, hizmet kalitesinin ve katma deėerinin artırılması ise ancak ulařım altyapısına yapılacak yatırım ile mmkn olmaktadır (Navickas et al., 2011: 235). Lojistik altyapısına yapılacak yatırımlar da hem üretim artışı ve rekabet edilebilirliğe hem de ekonomik büyümeye yol açmaktadır. Lojistik alt yapısına yapılacak yatırımların yol açacağı ekonomik büyüme etkisi ise řekil 4.2.'de gösterilmiştir. řekil 4.2.'ye göre; lojistik altyapısına yapılacak yatırımlar hem lojistik kapasitesinde hem de verimlilik, güvenilirlik, hizmet kalitesi ve katma deėerde bir artışa imkn tanımaktadır. Bu artış ise firmalar açısından daha düşük lojistik maliyetlere, lojistik sistem ierisinde daha kısa geiş hareketlerinin varlığına ve iş iin uygun kořulların oluřmasına sebep olmaktadır. Böylelikle; aslında lojistik hizmet kalitesinin ve verimliliėinin artması sanayi sektörnde üretkenlik artışına yol açmaktadır. Üretim ve hizmet sektörlerinin üretkenliğinde bir artış yaşanır iken aynı zamanda lkenin rekabet edilebilirliğine de katkı sunulmaktadır. Çünkü daha düşük maliyetler ve daha kısa geiş sürelerinin varlığı lojistik etkinliėin artmasına ve bu da rekabet gücü artışına sebep olmaktadır. Nihai olarak ise ekonomik büyüme meydana gelmektedir. Özetle; lkelerin ekonomik büyüme ve gelişme göstermesinde lojistik önemli bir rol stenmektedir (Murphy & Wood, 2015: 18-19; Gani, 2017: 279).



Şekil 4.2. Lojistiğin Ekonomik Büyüme Üzerindeki Etkisi (Navickas et al., 2011: 234).

4.4. Araştırma Modeli ve Veri Seti

Bu çalışmanın amacı; demiryolu altyapı yatırımlarının, kişi başına düşen demiryolu altyapı yatırımlarının, GSYH başına düşen toplam iç ulaşım altyapı yatırımlarının ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının ekonomik büyümeye etkisini incelemektir.

29 OECD üyesi ülkeye ait 5 adet değişkenin 2010-2019 dönemine ait yıllık verileri <https://stats.oecd.org/> web adresinden elde edilmiştir. Seçilen OECD üyesi ülkeler Tablo 4.2.'de, analizde kullanılan değişkenlere ait bilgiler ise Tablo 4.3.'de gösterilmiştir. Elde edilen verilerde her bir birim tüm zamanlar boyunca gözlenmiş olduğundan dengeli panel veri setinin varlığı söz konusudur. Ayrıca dengeli panel veri setinde birim boyutu zaman boyutundan büyük olduğu için (N>T) bu çalışma bir mikro panel uygulamasıdır.

Tablo 4.2. Panel Regresyon Analizi İçin Seçilen OECD Üyesi Ülkeler

Avusturalya	Çek Cumhuriyeti	Almanya	İtalya
Avusturya	Estonya	Yunanistan	Japonya
Belçika	Finlandiya	Macaristan	Kore
Kanada	Fransa	İrlanda	Letonya
Litvanya	Lüksemburg	Meksika	Yeni Zelanda
Norveç	Polonya	Slovenya	İspanya
İsveç	İsviçre	Türkiye	Birleşik Krallık
Amerika			

Tablo 4.3. Panel Regresyon Analizinde Kullanılan Değişkenler

Değişkenler	Kod	Birim
GSHY	GDP	Dolar (\$)
Demiryolu Altyapı Yatırımı	YH3	Euro
Kişi Başına Düşen Demiryolu Altyapı Yatırımı	UA4	-
GSYH Başına Düşen Toplam İç Ulaşım Altyapı Yatırımı	UA8	-
Uluslararası Havacılık Sığınaklarından Kaynaklanan CO ₂ Emisyonlarının Toplam CO ₂ Emisyonları İçerisindeki Payı	EC3	-

Mevcut literatürden yola çıkılarak bağımlı değişken GSYH (GDP); demiryolu altyapı yatırımının (YH3), kişi başına düşen altyapı yatırımının (UA4), GSYH başına düşen toplam iç ulaşım altyapı yatırımının (UA8) ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının (EC3) bir fonksiyonu olarak denklem (4.1) 'de tanımlanmıştır:

$$GDP = f(YH3, UA4, UA8, EC3) \quad (4.1)$$

Denklem (4.1)'in ekonomik modellemesi ise şu şekildedir:

$$GDP_t = \beta_0 + \beta_1 YH3_{it} + \beta_2 UA4_{it} + \beta_3 UA8_{it} + \beta_4 EC3_{it} + \varepsilon_{it} \quad (4.2)$$

(4.2) numaralı denklemde β_0 sabit terimi, i çalışmanın yatay kesitlerini (ülkeleri), t zamanı (2010, 2011.....2019), ε terimi ise hata terimini göstermektedir. Analizlerde (4.2) numaralı denklemde yer alan tüm değişkenler doğal logaritmaları alınarak kullanılmıştır.

4.5. Metodoloji ve Bulgular

Çalışmada demiryolu altyapı yatırımlarının, kişi başına düşen demiryolu altyapı yatırımlarının, GSYH başına düşen toplam iç ulaşım altyapı yatırımlarının ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının ekonomik büyümeye etkisi panel regresyon tahmini yapılarak incelenmiştir. Tahminin gerçekleştirilebilmesi için oluşturulan modeldeki veriler STATA 16 paket programında analize tabi tutulmuştur.

Tablo 4.4. Çoklu Doğrusal Bağlantının Varyans Büyütme Faktörü (VİF) İle Sınanması

Değişkenler	VİF	1/VİF
YH3	1.30	0.769860
UA4	2.00	0.500216
UA8	1.29	0.774862
EC3	1.44	0.692502
Ortalama VİF	1.51	

Çalışmada panel veri modelinin belirlenmesine ilişkin testler yapılmadan önce seçilen bağımsız değişkenler arasında çoklu doğrusal bağlantı probleminin varlığı Varyans Büyütme Faktörü (VİF) kriteri ile sınanmıştır. Çünkü modelde yer alan bağımsız değişkenler arasında çoklu doğrusal bağlantı olması sapmasız tahminler elde edilmesini engellemektedir (Yerdelen Tatoğlu, 2021: 274). VİF kriteri kullanılarak yapılan sınav sonuçları Tablo 4.4.'de gösterilmiştir. Buna göre VİF değeri 5'in altında ($1.51 < 5$) olduğu için modelde çoklu doğrusal bağlantı probleminin olmadığı söylenebilir.

4.5.1. Panel veri modelinin belirlenmesi

Panel veri modellerinde parametrelerin birim ve/veya zamana göre değer almasına bağlı olarak kullanılan farklı modeller yer almaktadır. Bunlardan en önemlileri sabit ve eğim parametrelerinin birimlere ve zamana göre sabit olduğunu varsayan havuzlanmış model (klasik model) ve tahmin edilen parametrelerin kesit ve/veya zaman boyunca sabit olmadığını varsayan sabit etkiler modeli ile rassal (tesadüfi) etkiler modelleridir (Greene, 2003: 285; (Yerdelen Tatoğlu, 2021: 62).

Panel veri analizlerinde hangi modelin kullanılması gerektiğini belirlemek üzere çeşitli testler mevcuttur. Bu testlerden biri de literatürde sıklıkla kullanılan F testidir. Moulton & Randolph (1989) tarafından önerilen F testi ile veri seti için havuzlanmış (klasik) modelin mi yoksa sabit etkiler modelinin mi uygun olduğu araştırılmaktadır. Kısacası F testi ile verilerin birimlere/zamana göre farklılık gösterip göstermediğine karar verilmektedir. F testi sonucunda verilerin birimlere/zamana göre farklılık göstermediği tespit edilmiş ise klasik modelin kullanılması uygun olacaktır. Aksine F testi sonucunda verilerin birimlere/zamana göre farklılık gösterdiği belirlenir ise klasik modelin uygun olmadığı sonucuna varılır. Böyle bir durumda klasik model ile tesadüfi etkiler modeli arasında seçim yapmak için birim etkilerin varyansının sıfır olduğu hipotezini alternatif hipoteze karşı sınavan Breusch & Pagan (1980) tarafından geliştirilen Lagrange Çarpanı

(LM) testi kullanılmaktadır. Breusch-Pagan LM testinin sonucunda sıfır hipotezi reddedilir ise klasik modelin uygun olmadığı sonucuna varılmaktadır (Yerdelen Tatoğlu, 2021: 177-186). Her iki testte de klasik modelin uygun olmadığı tespit edildiği takdirde ise tesadüfi etkiler modeli ile sabit etkiler modeli arasında seçim yapmak üzere Hausman (1978) testi uygulanmaktadır (Greene, 2003: 301).

Çalışmada ilk olarak klasik model sabit etkiler modeline karşı F testi ile sınanmıştır. Bu doğrultuda birim ve zaman etkilerin varlığının tespit edilebilmesi için ayrı ayrı F testi uygulanmıştır. Birim etkinin varlığını test etmek için yapılan F testi sonucunda H_0 hipotezi %1 anlamlılık düzeyinde reddedilir iken zaman etkisinin varlığını test etmek için yapılan F testi sonucunda H_0 hipotezi kabul edilmiştir. Kısacası modelde birim etkilerin varlığına rastlanmıştır ve bu nedenle havuzlanmış modelin uygun olmadığı tespit edilmiştir.

Klasik modelin uygun olmadığının tespit edilmesinin ardından klasik model, tesadüfi etkiler modeline karşı Breusch-Pagan LM testi kullanılarak sınanmıştır. Elde edilen bulgulara göre birim etkilerin varyansının sıfıra eşit olduğunu savunan temel hipotez %1 anlamlılık düzeyinde reddedilmiş ve veri seti için klasik modelin uygun olmadığı saptanmıştır. F testi ve Breusch-Pagan LM Testi sonuçları Tablo 4.5.'de gösterilmiştir.

Tablo 4.5. Panel Etkilerin Varlığının Sınanması

Breusch-Pagan LM Testi Sonuçları	
Ho: $\sigma^2_u = 0$ (Birim etkilerin varyansı sıfıra eşittir).	
chibar2(01)= 81.03	Prob>chibar2= 0.0000
Birim Etki İçin F Testi Sonuçları	
Ho: $\mu_i = 0$ (Birim Etki Yoktur).	
F(28, 257) = 758.88	Prob > F = 0.0000
Zaman Etkisi İçin F Testi Sonuçları	
Ho: $\lambda_t = 0$ (Zaman Etkisi Yoktur).	
F(9, 276) = 1.45	Prob > F = 0.1683

Veri seti için klasik modelin uygun olmadığının tespit edilmesinin ardından tesadüfi etkiler modeli ile sabit etkiler modeli arasında seçim yapmak üzere Hausman (1978) testi uygulanmıştır. Tablo 4.6.'da görüldüğü üzere tesadüfi etkiler modelinin geçerli olduğunu savunan temel hipotez %1 anlamlılık düzeyinde reddedilmiştir. Bu doğrultuda veri seti için sabit etkiler modelinin geçerli olduğu sonucuna varılmıştır.

Tablo 4.6. Hausman Testi Sonuçları

	Katsayılar		
	(b) Sabit Etki	(B) Tesadüfi Etki	(b-B) Sabit-Tesadüfi
lnYH3	.0037358	.0342793	-.0305435
lnUA4	.0167396	-.0210975	.0378371
lnUA8	-.1153454	-.1232624	.007917
ln EC3	.5449937	.4834013	.0615924

Ho: $E(\alpha_{it}) = 0$ ((Katsayılar arasındaki fark sistematik değildir (Tesadüfi etkiler modeli geçerlidir)).

chi2(4) = 198.14

Prob>chi2 = 0.0000

Panel veri modellerinde değişen varyans (heteroskedasite), ardışık bağımlılık (otokorelasyon) ve birimler arası korelasyonun (yatay kesit bağımlılığı) bulunmadığına dair üç temel varsayım bulunmaktadır. Bu varsayımlardan sapmalar tahmincilerin etkinliğinin bozulmasına sebep olmaktadır (Yerdelen Tatoğlu, 2021: 227-229). Öyle ki yatay kesit verilerinde hata terimlerinin varyansının değişken olması sıklıkla karşılaşılan bir durumdur ve mutlaka değişen varyansı dikkate alan tahmincilerin kullanımını gerektirmektedir (Long & Ervin, 2000: 2). Öte yandan hataların korelasyonlu olması taraflı standart hataların oluşmasına ve dolayısı ile verimsiz tahminlere yol açmaktadır (Born & Breitung, 2015: 1). Bu nedenle ardışık bağımlılığın mutlaka test edilmesi gerekmektedir. Son olarak ise; iktisadi problemlerin çözümü için kullanılan panel veri modellerinde hata terimlerinin birbirlerine göre bağımsız olmaması yani birimler arasındaki heterojenlik sıklıkla karşılaşılan merkezi bir problemdir. Nitekim heteroskedasitenin varlığı elde edilen sonuçlarda ciddi problemlerin ortaya çıkmasına sebebiyet vermektedir. Bu nedenle değişen varyans probleminin varlığı mutlaka test edilmeli ve gerekirse tahmin yöntemleri buna göre değiştirilmelidir (Greene, 2003: 222; Chudik & Pesaran, 2013: 2). Bu doğrultuda panel veri modelinde varsayımlardan sapmaların olup olmadığı incelendikten sonra uygun tahmin yöntemi kullanılmalıdır.

Çalışmada veri seti için sabit etkiler modelinin uygun olduğu saptandığı için varsayım testleri bu model üzerinden ele alınmıştır. Sabit etkiler modelinde değişen varyans varsayımından sapmaların belirlenmesi için Greene (2000) tarafından geliştirilen Değiştirilmiş Wald Testi tercih edilmiştir. Otokorelasyon sorununun tespiti için Bhargava, Franzini ve Narendranathan'ın Durbin Watson ve hem sabit hem de tesadüfi etkili panel veri modelleri için kullanılabilen Baltagi Wu'nun Yerel En İyi Değişmez Testleri birlikte kullanılmıştır. Yatay kesit bağımlılığının sınanması için ise küçük T ve büyük N içeren

çeşitli panel veri modellerine uyarlanabilen Pesaran (2004) CD (Baltagi, 2005: 247) testi tercih edilmiştir. Test sonuçları Tablo 4.7.'de gösterilmiştir.

Tablo 4.7. Sabit Etkiler Modelinde Değişen Varyans, Otokorelasyon ve Birimler Arası Korelasyonun Sınanması

Değiştirilmiş Wald Testi Sonuçları	
Ho: $\sigma^2_i = \sigma^2$ (varyanslar birimlere göre homoskedastiktir)	
chi2 (29) = 2472.68	Prob > chi2 = 0.0000
Bhargava, Franzini ve Narendranathan'ın Durbin Watson ve Baltagi Wu'nun Yerel En İyi Değişmez Testleri	
Ho: $\rho = 0$ (otokorelasyon yoktur).	
Durbin Watson = 0.59254694	
Baltagi-Wu LBI = 1.0288442	
Pesaran CD Testi	
Ho: Birimler arası korelasyon yoktur.	
Pesaran CD = 8.506	Pr = 0.0000

Tablo 4.7.'de yer alan Değiştirilmiş Wald Testi sonuçlarına göre temel hipotez %1 anlamlılık düzeyinde reddedilmiş ve modelde değişen varyans problemi bulunduğu saptanmıştır. Ayrıca hem Durbin Watson hem de Baltagi-Wu Testlerinin test istatistiği değerleri 2'den küçük çıkmıştır. Dolayısı ile modelde otokorelasyon problemi olduğu tespit edilmiştir. Pesaran CD Testi sonuçlarına göre ise; temel hipotez %1 anlamlılık düzeyinde reddedilerek modelde yatay kesit bağımlılığının bulunduğu belirlenmiştir.

4.5.2. Panel regresyon analizi

Modelde değişen varyans, otokorelasyon ve yatay kesit bağımlılığının bulunması parametre varyanslarının ve dolayısı ile de standart hataların, F ve t istatistiklerinin, güven aralıklarının ve R^2 'nin geçerliliğini etkilemektedir. Bu nedenle modelde değişen varyans, otokorelasyon veya yatay kesit bağımlılığından en az biri mevcut ise ya parametre hatalarına dokunulmadan standart hatalar düzeltilerek dirençli standart hatalar elde edilmeli ya da uygun yöntemler ile tahminler yapılmalıdır (Yerdelen Tatoğlu, 2021: 327).

Çalışmada oluşturulan mikro panel veri modelinde değişen varyans, yatay kesit bağımlılığı ve otokorelasyon problemlerinin bulunduğu tespit edilmiştir. Bu nedenle bu çalışmada hem $N > T$ durumunda hem de değişen varyans, yatay kesit bağımlılığı ve otokorelasyon problemlerinin bulunduğu durumlarda güçlü tahminler üretebilen Driscoll & Kraay (1998) dirençli tahmincisi tercih edilmiştir.

Tablo 4.8. Sabit Etkili Driscoll-Kraay Tahmincisi Sonuçları

F (4, 9) = 266.24		Prob > F = 0.0000	R ² = 7263
	Katsayı	Standart Hata	Olasılık Değeri
lnGSYH			
lnYH3	0.003	.0066215	0.586
lnUA4	0.016	.0203064	0.431
lnUA8	-0.115**	.0374859	0.013
lnEC3	0.544*	.0339597	0.000
B0	12.536	.2138001	0.000

*: %1 ve **: %5 anlamlılık seviyesini simgeler.

Seçilen bağımsız değişkenlerin GSYH üzerindeki etkisini gösteren regresyon tahminine ilişkin bulgular Tablo 4.8.'de gösterilmiştir. Tabloya göre demiryolu altyapı yatırımı (YH3) ve kişi başına düşen demiryolu altyapı yatırımının (UA4) GSYH üzerindeki etkisi istatistiki olarak anlamsız iken GSYH başına düşen toplam iç ulaşım altyapı yatırımı (UA8) ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının (EC3) GSYH üzerindeki etkisi istatistiki olarak anlamlıdır. Buna göre GSYH başına düşen toplam iç ulaşım altyapı yatırımında yaşanan %1'lik artış GSYH'yı %0.115 azaltır iken; uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payında yaşanan %1'lik bir artış GSYH'yı %0.544 arttırmaktadır.

4.6. Tartışma

Demiryolu altyapı yatırımlarının, kişi başına düşen demiryolu altyapı yatırımlarının, GSYH başına düşen toplam iç ulaşım altyapı yatırımlarının ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının ekonomik büyümeye etkisinin panel veri analiz yöntemleri ile ortaya koyulmasını amaçlayan bu çalışmada elde edilen bulgular dikkat çekicidir. Nitekim literatürdeki çoğu çalışmada (Badalyan et al., (2014); Hayaloğlu (2015); Gherghina et al., (2018); Kabaklarlı et al., (2018); Kara & Cığırlioğlu, (2018); Wang et al., (2020); Samir, & Mefteh (2020); Pradhan et al., (2021); Zheng et al., (2024)) ulaşım altyapı yatırımlarının ekonomik büyüme üzerinde anlamlı ve pozitif etkiye sahip olduğu veya altyapı yatırımları ile ekonomik büyüme arasında nedensellik ilişkisinin bulunduğu tespit edilmiştir. Fakat bu çalışmada yukarıda bahsedilen çalışmaların aksine demiryolu altyapı yatırımının ve kişi başına düşen demiryolu altyapı yatırımının GSYH üzerinde istatistiksel olarak anlamlı bir etkiye sahip olmadığı saptanmıştır. Bu sonuç ulaşım altyapısı ile ekonomik büyüme arasında ilişki bulunmadığını tespit eden Şen & Yılmaz (2023) ile benzerdir. Çalışmada genel literatürün aksine böyle bir sonucun çıkmasının birkaç farklı nedeni olduğu düşünülmektedir. Bunlardan ilki; uzun vadeli projeler olan

demiryolu yatırımlarının ekonomik etkilerinin kısa bir zaman diliminde belirgin şekilde ortaya çıkmamış olmasıdır. Nitekim bu çalışmada sadece 2010-2019 yılları arasındaki verilerle bir mikro panel uygulaması gerçekleştirilmiştir. Bu kapsamda 10 yıl gibi kısa bir süreçte demiryolu altyapı yatırımlarının ekonomik etkileri ortaya çıkmamış olabilir. İkincisi; OECD ülkelerinin çoğunda demiryolu ulaşımının mevcut ve iyi durumda olmasıdır. Öyle ki günümüzde gelişmiş yüksek hızlı demiryolu ağları ile tanınan Almanya ile Fransa'nın 2014 yılında elektrikli ve elektriksiz demiryolu ağlarının toplam uzunluğu sırası ile 38.658 km ve 29.568 km'dir. 2023 yılına gelindiğinde ise bu rakamlar sırası ile 38.691 km ve 27. 617 km olmuştur. Dolayısı ile görüldüğü üzere özellikle gelişmiş demiryolu ağı bulunan OECD üyesi ülkelerde demiryolu altyapı yatırımları genellikle modernizasyonla sınırlı kalmaktadır. Üçüncüsü ise; OECD ülkelerinin bazılarında ekonomik zorluklar, coğrafi yapı ve/veya ulaşım politikası farklılıkları nedeni ile demiryolu altyapı yatırımlarının sınırlı kalmasıdır. Öyle ki 2023 yılı itibari ile elektrikli ve elektriksiz toplam demiryolu uzunluğuna bakıldığında Lüksemburg (271 km), Slovenya (1.208 km), Estonya (1.171 km), Yunanistan (1.822 km) gibi ülkelere demiryolu altyapı yatırımlarının oldukça sınırlı kaldığı söylenebilir (https://ec.europa.eu/eurostat/databrowser/view/rail_if_line_ga/default/table?lang=en&category=rail.rail_if Erişim tarihi: 26.08.2025). Bahsedilen tüm bu faktörlerin demiryolu altyapı yatırımlarının meydana getireceği ekonomik büyüme etkisinin ortaya çıkmasına engel olduğu düşünülmektedir.

Literatürdeki çoğu çalışmanın bulgularından farklı olarak bu çalışmada elde edilmiş önemli bulgulardan bir diğeri ise; GSYH başına düşen toplam iç ulaşım altyapı yatırımının ekonomik büyüme üzerinde negatif bir etkiye sahip olduğudur. Bu bulgu Çin'de ulaşım altyapı yatırımları ile ekonomik büyüme arasında negatif bir ilişkinin varlığına rastlayan Apurv, & Uzma (2021)'e benzerdir. Bu kapsamda öncelikle iyi planlama yapılmamış yatırımların ekonomik büyümeyi engellemesinin kaçınılmaz olduğu söylenebilir. Nitekim altyapı planlama ve teslim endeksinde OECD ülkelerinin taşımacılık sektörüne ilişkin planlama yapma ortalaması 2022 yılında 0.65'tir. Avustralya (0.63), Belçika (0.49), Çek Cumhuriyeti (0.41), Estonya (0.61), Fransa (0.33), Almanya (0.52), İrlanda (0.56), Yeni Zelanda (0.48), Norveç (0.59), Portekiz (0.56) ve Türkiye (0.14) ile bu ortalamanın altında kalan ülkelerdir (<https://data-explorer.oecd.org/> Erişim tarihi: 27.08.2025). Bu rakamlar bahsedilen OECD ülkelerinin taşımacılık altyapısı konusunda etkin planlama yapamadıklarını göstermektedir. Bir diğer taraftan yaşanan

ekonomik krizler ve kamu borçları da altyapı yatırımlarının meydana getireceği ekonomik büyümeyi engelleyebilmektedir. Öyle ki tüm dünyada etkisini gösteren 2008 Küresel Krizi sonrasında 2009 yılında OECD ülkelerinin devlet harcamalarının ortalamasının GSYH başına düşen yüzdesi 4.13 iken 2019 yılına kadar bu rakam 3.34'e gerilemiştir. Ayrıca aynı dönemde devlet borçlarında da artışlar yaşanmıştır. OECD ülkelerinin brüt devlet borçlarının ortalamasının GYSH başına düşen yüzdesi 2008 yılında 77.05 iken bu rakam 2019 yılında 106.76'ya çıkmıştır (<https://data-explorer.oecd.org/> Erişim tarihi: 27.08.2025).

Son olarak her türlü ulaşımdan kaynaklanan CO₂ emisyonlarının kişi başına düşen GSYH üzerinde olumsuz etkileri olduğunu saptayan Gherghina et al., (2018)'in aksine bu çalışmada uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının GSYH üzerinde pozitif bir etkisinin olduğu tespit edilmiştir. Öyle ki OECD ülkelerinde turizm ve uluslararası ticaret nedeniyle yoğunlaşan yolcu ve kargo taşımacılığı dolayısı ile artan hava trafiğinin ekonomik büyümeyi de olumlu yönde etkilediği ve böyle bir sonucun ortaya çıktığı düşünülmektedir. Nitekim ton-kilometre cinsinden bin Amerikan doları başına düşen havayolu yük taşımacılığı 2010 yılında Amerika'da 2.6, Almanya'da 2.2, Fransa'da 1.9 ve Birleşik Krallık'ta 2.4 iken 2021 yılında bu rakamlar sırası ile 1.9, 2.7, 1.4 ve 1.3 olarak gerçekleşmiştir (<https://data-explorer.oecd.org/> Erişim tarihi: 30.08. 2025). Ayrıca gelişmiş havayolları ile bilinen Almanya'da 2013 yılında 180.783.188, Fransa'da 132.762.87, İtalya'da 115.279.105, Birleşik Krallık'ta 210.468.980 ve popüler turizm destinasyonlarından olan Yunanistan'da 34.023.934 ve İspanya'da 157.731.973 yolcu taşınmıştır. Bu rakamlar 2019 yılında Almanya'da 226.764.086, Fransa'da 168.726.788, İtalya'da 160.667.939, Birleşik Krallık'ta 277.432.380, Yunanistan'da 56.088.527 ve İspanya'da 228.262.372 olarak gerçekleşmiştir (<https://ec.europa.eu/> Erişim tarihi: 31.08.2025). Dolayısı ile özellikle bu ülkelerde ve diğer OECD ülkelerinde gerçekleşen yolcu ve mal taşımacılığı yoğun bir uluslararası hava trafiğine sebep olmakla birlikte gerçekleşen taşımacılık faaliyeti de ekonomik büyüme üzerinde pozitif etkiye sebebiyet vermektedir.

4.7. Çıkarımlar

4.7.1. Teorik ve uygulama çıkarımları

OECD ülkelerinin demiryolu altyapı yatırımları, iç ulaşım altyapı yatırımları ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının ekonomik büyüme üzerindeki etkini Driscoll-Kraay dirençli tahmincisi ile inceleyen bu mikro panel uygulamasından hem araştırmacılar hem de politika belirleyiciler önemli ölçüde faydalanacaklardır. Teorik katkılar açısından ilk olarak, mevcut literatürden farklı olarak ilk kez bu çalışmada demiryolu ve iç ulaşım altyapı yatırımlarına ek olarak uluslararası havacılık sığınaklarının GSYH üzerindeki etkisi incelenmiştir. Nitekim sürdürülebilirlik uygulamalarının önem kazandığı ve özellikle Avrupa Birliği üyesi ülkelerin CO₂ emisyonlarını azaltma hedefleri düşünüldüğünde çalışmada kurulan teorik modelin ek araştırmalar için önemi dikkat çekicidir. Son olarak ise, bu çalışma ile dirençli tahmincilerin öngörü gücü bir kez daha ortaya çıkarılmıştır.

Araştırmacılar ve OECD ülkelerinin politika belirleyicileri için de önemli uygulama çıkarımları sunan bu çalışma ilk olarak, mevcut literatürün aksine OECD ülkelerinde demiryolu altyapı yatırımlarının ekonomik büyüme üzerindeki etkisinin on yıllık bir süreçte ortaya çıkmadığını ortaya koydu. Bu doğrultuda mutlaka altyapı yatırımlarının uzun vadeli etkileri dikkate alınarak ülkelere özgü uygun politika çıkarımlarında bulunulması gerekmektedir. Aynı zamanda araştırmacıların demiryolu altyapı yatırımlarının ekonomik büyüme üzerindeki etkisinin ortaya çıkış zamanını daha detaylı şekilde analiz etmeleri yararlı olacaktır. İkincisi, literatürden farklı olarak çalışmada OECD ülkelerinde GSYH başına düşen toplam iç ulaşım altyapı yatırımının ekonomik büyüme üzerinde istatistiki olarak anlamlı ve negatif bir etkiye sahip olduğu belirlenmiştir. Bu kapsamda OECD ülkelerinde uygun planlamalar dahilinde ve kaynakları etkin şekilde yöneterek iç ulaşım altyapı yatırımlarının hayata geçirilmesi yararlı olacaktır. Üçüncü ve son olarak, yoğun havayolu kargo ve yolcu taşımacılığı ile dikkat çeken OECD ülkelerinde CO₂ emisyonlarının ekonomik büyüme üzerindeki pozitif etkisinin ortaya çıkarılmasını sağlayan bu çalışma, literatüre katkı sunmaktadır. Öyle ki çalışmanın bulguları, havayolu trafiğinin sebep olduğu çevresel tahribatı azaltacak politikaların hayata geçirilmesinin önemini ortaya koyar iken; araştırmacıların da CO₂ emisyonlarının sürdürülebilir büyüme üzerindeki etkisini araştırmalarının gerekliliğini gözler önüne sermektedir.

4.8. Sonuç ve Öneriler

Küresel dünya düzeninin var olduğu günümüzde, taşımacılık başta olmak üzere tüm lojistik imkanlar uluslararası ticarete her zamankinden daha fazla belirleyici olmaya başlamıştır. Öyle ki iyi tasarlanmış bir lojistik sistem içerisinde gerçekleştirilen hızlı, güvenilir ve ucuz taşımacılık faaliyeti ile ülkelerin küresel dış ticaretten pay elde etmeleri kolaylaşır iken ekonomik faaliyetlerde de canlanma görülecektir. Bu doğrultuda etkin bir taşımacılık faaliyeti gerçekleştirmenin ve böylelikle dünya ekonomisi ile bütünleşmenin anahtarı ulaşım altyapısına yapılan yatırımlardır. Çünkü bir ülkede ulaşım altyapısının yetersiz kalması halinde mal ve hizmetlerin dağıtımı yani taşımacılık faaliyeti zamanında ve beklentileri karşılayacak şekilde gerçekleşemeyecek ve bu da ekonomik anlamda gelişimi kısıtlayabilecektir. Bu kapsamda bu çalışmanın amacı, demiryolu altyapı yatırımlarının, kişi başına düşen demiryolu altyapı yatırımlarının, GSYH başına düşen toplam iç ulaşım altyapı yatırımlarının ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının ekonomik büyümeye etkisini panel veri analiz yöntemleri ile analiz etmektir. Bu amaç doğrultusunda OECD üyesi 29 ülkenin 2010-2019 dönemini kapsayan yıllık verilerinin doğal logaritmaları kullanılarak bir mikro panel uygulaması gerçekleştirilmiştir. Elde edilen ikincil veriler STATA 16 paket programında analize tabi tutulmuştur. Çalışmada öncelikle panel veri modelinin belirlenmesi amacı ile klasik modelin geçerliliği F testi kullanılarak sınanmıştır. Klasik model ile sabit etkiler modeli arasında seçim yapmak üzere birim ve/veya zaman etkilerinin olup olmadığını sınoyan F Testi sonucunda modelde birim etkilerin varlığına rastlanmış ve bu nedenle klasik modelin uygun olmadığına karar verilmiştir. Ardından klasik model ile tesadüfi etkiler modeli arasında seçim yapmak üzere Breusch-Pagan LM testi kullanılmıştır. Breusch-Pagan LM testi sonucunda klasik modelin geçerli olmadığı saptanmıştır. Yapılan testler sonucunda klasik modelin uygun olmadığına belirlenmesinin ardından sabit etkiler modeli ile tesadüfi etkiler modeli arasında seçim yapabilmek üzere Hausman Testi kullanılmıştır. Hausman Testi sonucunda sabit etkiler modelinin uygun olduğuna karar verilmiştir. Sabit etkiler modelinde değişen varyans varsayımından sapmaların tespiti için Değiştirilmiş Wald Testi, otokorelasyon sorununun tespiti için Baltagi Wu'nun Yerel En İyi Değişmez Testleri ve yatay kesit bağımlılığının sınanması için de Pesaran CD Testi kullanılmıştır. Elde edilen sonuçlara sabit etkiler modelinde değişen varyans, otokorelasyon ve yatay

kesit bağımlılığının bulunduğunu gösterdiği için ve çalışmada $N > T$ olduğu için dirençli bir tahminci olan Driscoll-Kraay kullanılarak regresyon analizi gerçekleştirilmiştir.

Çalışmanın sonucunda; OECD ülkelerinde demiryolu altyapı yatırımı ve kişi başına düşen demiryolu altyapı yatırımının GSYH üzerindeki etkisinin istatistiki olarak anlamsız olduğu tespit edilmiştir. Nitekim demiryolu altyapı yatırımlarının uzun vadeli projeler olması ekonomik etkilerinin de on yıl gibi kısa bir zaman diliminde ortaya çıkmasına engel olabilmektedir. Ayrıca OECD ülkelerinin çoğunda demiryolu ağırları mevcut ve iyi durumdadır. Dolayısı ile özellikle gelişmiş ülkeler olarak nitelendirilebilecek Almanya ve Fransa gibi ülkelere demiryolu altyapı yatırımları modernizasyon ile sınırlı kalmaktadır. Son olarak ise; Lüksemburg, Slovenya, Estonya ve Yunanistan gibi ülkelere ulaşım politikası farklılıkları, coğrafi özellikler ve/veya ekonomik nedenler ile demiryolu altyapı yatırımları sınırlı kalmıştır. Tüm bu faktörlerin OECD ülkelerinde demiryollarına yapılan altyapı yatırımlarının sınırlı kalmasına ve ekonomik büyüme üzerinde istenilen etkiyi sağlayamamasına neden olduğu söylenebilir.

OECD ülkelerinde GSYH başına düşen toplam iç ulaşım altyapı yatırımının GSYH üzerinde istatistiki olarak anlamlı ve negatif bir etkiye sahip olduğu tespit edilmiştir. Nitekim GSYH başına düşen toplam iç ulaşım altyapı yatırımında yaşanan %1’lik artışın GSYH’yi %0.115 azalttığı tespit edilmiştir. İç ulaşım altyapı yatırımları genellikle uzun vadeli ve yüksek bütçeli projeler olduğu için öncelikle iyi bir planlama yapılması gerekmektedir. Fakat Avustralya, Belçika, Çek Cumhuriyeti, Estonya, Fransa, Almanya, İrlanda, Yeni Zelanda, Norveç, Portekiz ve Türkiye’nin taşımacılık altyapı yatırımlarına ilişkin planlama yapma ortalamaları OECD ortalamasının altındadır. Ayrıca yaşanan ekonomik krizler ve kamu borçları da altyapı yatırımlarının sebep olacağı ekonomik büyümeyi engelleyebilmektedir. Nitekim 2008 Küresel Krizi sonrasında OECD ülkelerinin devlet yatırımlarında ciddi düşüşler yaşanır iken kamu borçlarında da artışlar meydana gelmiştir. Öyle ki iyi planlama yapılmamış, kaynakları etkin şekilde yönetilmemiş ve borçla veya kamu kaynakları ile finanse edilmiş yatırımların ekonomik büyümeyi engellemesinin kaçınılmaz olduğu söylenebilir. O halde OECD ülkelerinde iç ulaşım altyapı yatırımlarının iyi bir planlama sonrasında mali baskı oluşturmayacak şekilde öz kaynaklar kullanılarak yapıldığı takdirde ekonomik büyümeyi sağlayacağını söylemek mümkündür.

Son olarak; uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının GSYH üzerindeki etkisinin

istatistiki olarak anlamlı ve pozitif olduğu belirlenmiştir. Uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payında yaşanan %1’lik bir artışın GSYH’yı %0.544 arttırdığı saptanmıştır. OECD ülkelerinden ekonomik büyüklükleri ile dikkat çeken Amerika, Almanya, Fransa ve Birleşik Krallık’ta havayolu yük taşımacılığı oldukça yoğundur. Ayrıca gelişmiş havayollarına sahip Almanya, Fransa, İtalya, Birleşik Krallık ve popüler turizm destinasyonlarından Yunanistan ve İspanya’da havayolu yolcu taşımacılığı yoğun şekilde gerçekleşmektedir. Dolayısı ile özellikle bu ülkelerde ve diğer OECD ülkelerinde gerçekleşen yolcu ve mal taşımacılığı da yoğun bir uluslararası hava trafiğine sebep olmaktadır. Yoğun uluslararası hava trafiği ise havacılıktan kaynaklanan CO₂ emisyonlarını arttırmaktadır. Kısacası OECD ülkelerindeki CO₂ emisyonlarının oluşmasının sebebi turizm ve uluslararası ticarettir. Turizm ve uluslararası ticaret dolayısı ile artan hava taşımacılığı ise, ekonomik büyümenin önemli bir unsurudur. Fakat artan hava trafiğinin sebep olduğu CO₂ emisyonlarının sürdürülebilir büyüme üzerindeki etkisi mutlaka analiz edilmeli ve çevresel tahribatın engellenmesi için gerekli önlemler alınmalıdır. Bu önlemler arasında sürdürülebilir turizmin desteklenmesi, sürdürülebilir havacılık yakıtlarının kullanımı ile emisyon ticareti ve karbon vergisi uygulamaları yer alabilir.

4.9. Çalışmanın Kısıtlılıkları ve Gelecekle İlgili Yönelimler

Çalışmada elde edilen sonuçların literatüre katkı sunması ve OECD ülkelerinin politika belirleyicilerine yol göstermesi beklenmektedir. Fakat elde edilen sonuçlara bazı kısıtlılıklar çerçevesinde ulaşılmıştır. Nitekim çalışmada sadece 29 adet OECD üyesi ülkeye ait dört adet bağımsız değişkenin ekonomik büyüme üzerindeki etkisi 2010-2019 dönemlerini kapsayan yıllık veriler ile analiz edilmiştir. Bu kapsamda ileride yapılacak çalışmalarda öncelikle 38 OECD üyesi ülkenin hepsinin çalışmanın örneklemini oluşturması elde edilen sonuçların genellenebilirliğine katkı sunacaktır. Diğer yandan değişken sayısı artırılarak model geliştirilebilir. Öyle ki demiryolu altyapı yatırımlarının GSYH üzerinde istatistiksel olarak bir etkisinin olup olmadığını saptamak adına ülkelerin elektrikli ve elektriksiz demiryolu ağlarının uzunluğuna ilişkin bağımsız değişkenler modele dahil edilebilir. İç ulaşım altyapı yatırımlarının GSYH üzerindeki etkisini değerlendirmek adına ise taşımacılıkta altyapı planlama ve teslim endeksi ile kamu borçları bağımsız değişkenlerinin modelde yer almasının faydalı olacağı düşünülmektedir. Ayrıca havayolu yük ve yolcu taşımacılıkları ile havayolu trafiğine

ilişkin değişkenlerin modele eklenmesi de uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının GSYH üzerindeki etkisini değerlendirmek adına modele eklenebilir. Son olarak ise; kurulan panel veri modellerinde bu çalışmadaki mikro panel uygulamasında kullanılan on yıllık zaman periyodunun aksine daha uzun bir zaman periyodu seçilerek makro panel uygulaması gerçekleştirilebilir. Özellikle 2008 Küresel Krizinin ve Covid-19 Krizinin etkilerinin incelenmesi adına 2008 yılı öncesini ve 2019 yılı sonrasını içeren bir zaman periyodunun seçilmesi faydalı olacaktır.



5. SONUÇ

Teknolojik gelişmeler her gün veri tabanlarında çok büyük miktarda verinin birikmesine sebebiyet vermektedir. Bu nedenledir ki günümüzde veri tabanlarında biriken büyük veri yığınları içerisindeki örüntülerin özel algoritmalar yardımı ile keşfedilmesi ve aralarından çeşitli kurum ve kuruluşlar için yararlı olabilecek bilgilerin açığa çıkarılması büyük önem taşımaktadır. Çünkü veriler akıl almaz bir hızla veri tabanlarında birikir iken, bu veri setinin yönetilmesi de bir o kadar zorlaşmaktadır. Bu kapsamda da büyük verinin bulunduğu her alanda gün geçtikçe veri madenciliği uygulamalarına duyulan ihtiyaç artmaktadır.

Büyük veri, çok çeşitli bilim alanlarında karşımıza çıkmaktadır. Ekonomi ve lojistik de bu alanların başında gelmektedir. Nitekim ekonomi ve lojistik alanlarında biriken büyük veriden faydalı kalıpların açığa çıkarılması ve yeni eğilimlerin keşfedilmesi araştırmacılar, çeşitli kurumlar ve politika yapıcılar için oldukça yararlı olacaktır. Özellikle de ekonomik açıdan gelişmek isteyen ülkelerde lojistik sektöründe var olan eksikliklerin tespit edilmesi, bu eksikliklerin giderilerek lojistik göstergelerin iyileştirilmesi adına doğru politikalar üretmek oldukça büyük önem taşımaktadır. Bu kapsamda ekonomi ve lojistik alanlarında biriken büyük veri yığınlarının özel algoritmalar yardımı ile analiz edilmesi için veri madenciliği sürecine ihtiyaç duyulduğu aşikardır. Bu çalışmanın amacı, OECD ülkelerinin ekonomi ve lojistik alanlarında biriken büyük verinin veri madenciliği yöntemleri ile analiz edilmesi ve ortaya çıkarılan yararlı bilgiler ışığında kapsamlı politika çıkarımlarının gerçekleştirilmesidir. Bu doğrultuda örneklem olarak 29 OECD üyesi ülkenin seçildiği veri madenciliği sürecine ilişkin analizler dört adımda gerçekleştirilmiştir. İlk adımda, OECD ülkelerine ait GSYH, ihracat, ithalat, enflasyon ve işsizlik oranı değişkenleri ile 2013-2022 dönemlerine ait yıllık veriler kullanılarak WEKA 3.8.6 yazılımında ayrı ayrı kümeleme analizi gerçekleştirilmiştir. Kümeleme analizinde üstün özelliklerinden dolayı hiyerarşik olmayan veri madenciliği yöntemlerinden k-ortalamlar algoritması tercih edilmiştir. Analiz sonucunda ülkeler dört kümeye ayrılmıştır. Almanya ve ABD'nin en gelişmiş ülkeleri barındıran kümede; Belçika, Fransa, Japonya, Kanada, Kore ve Birleşik Krallık'ın ise gelişmiş ülkelere yakın kümede oldukları tespit edilmiştir. Gelişmekte olan ülkelerin bulunduğu kümede Yunanistan ve İspanya yer alır iken; Türkiye'nin son yıllarda gelişmekte olan ülkelere yakın kümede bulunduğu görülmüştür. Estonya, Letonya ve Litvanya'nın ise az gelişmiş ülkeleri temsil eden kümede birlikte yer aldıkları

belirlenmiştir. Analizin ikinci aşamasında, WEKA 3.8.6 yazılımında J48 algoritması kullanılarak karar ağaçları ile sınıflandırma yapılmıştır. Kümeleme analizi sonucunda elde edilen nominal hedef değişkenler ve tahminleyici olarak 29 OECD üyesi ülkeye ait 20 adet taşımacılık değişkeninin 2019 yılına ait nümerik veriler kullanılmıştır. Analiz sonucunda OECD ülkelerinin ekonomik gelişme düzeylerinde farklılığa sebep olan değişkenlerin demiryolu altyapı yatırımı, GSYH başına düşen toplam iç ulaşım altyapı yatırımı, kişi başına düşen demiryolu altyapı yatırımı ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payı olduğu tespit edilmiştir. Analizin üçüncü aşamasında, OECD ülkelerinin ekonomik gelişme düzeyleri arasında farklılığa sebep olduğu belirlenen bu dört adet taşımacılık değişkenine ait 2025 yılı projeksiyonu oluşturulmuştur. Öyle ki WEKA 3.8.6 yazılımında popüler bir ileri beslemeli yapay sinir ağı türü olan çok katmanlı ağlar kullanılarak her bir OECD üyesi ülke için ayrı ayrı öngörüler gerçekleştirilmiştir. Analiz sonucunda öncelikle MAPE değeri dikkate alınarak çok katmanlı ağların öngörü performansı değerlendirilmiştir. Bu kapsamda analizlerin büyük bölümde MAPE değeri oldukça küçük çıkmış ve yapay sinir ağlarının iyi bir öngörü performansına sahip olduğu belirlenmiştir. ÇKA ile yapılan analiz sonucunda ikinci olarak, Avustralya, Avusturya, Belçika, Kanada, Çek Cumhuriyeti, Estonya, Litvanya, Lüksemburg, Meksika, Norveç, Japonya, İspanya, İsveç, İsviçre, Türkiye ve Birleşik Krallık'ta demiryolu altyapı yatırımlarının 2019-2023 döneminde bazı yıllarda Covid-19 pandemisinin yarattığı ekonomik belirsizlik sebebi ile azaldığı tespit edilmiştir. Fakat iç piyasa dinamikleri sürekli değişen Belçika ve Türkiye haricinde bahsedilen diğer ülkelerde demiryolu altyapı yatırımlarının 2025 yılında modernizasyon ve çevre dostu ulaşımın sağlama hedefleri doğrultusunda artışa geçeceği öngörülmüştür. ÇKA ile yapılan analizde üçüncü olarak; kişi başına düşen demiryolu altyapı yatırımlarının Avustralya, Avusturya, Litvanya, Norveç ve Birleşik Krallık'ta mevcut hatların modernizasyonu ve yeni hatların inşa edilmesinin etkileri ile 2025 yılında artacağı; hükümetlerin değişen öncelikleri ve iç piyasa dinamiklerinin etkileri ile Kanada, Finlandiya, Fransa ve Türkiye'de ise aynı yıl düşüş yaşanacağı öngörülmüştür. ÇKA ile yapılan analizde dördüncü olarak; zaten gelişmiş iç ulaşım altyapı yatırımlarına sahip olan İskandinav ülkelerinden İsveç'te 2022 yılı sonrasında, Finlandiya'da 2023 yılı sonrasında GSYH başına düşen toplam iç ulaşım altyapı yatırımlarında sürekli bir azalışın yaşanacağı; Norveç'te ise 2023 ve 2025 yıllarında keskin düşüşler olacağı öngörülmüştür. Aynı zamanda Türkiye'de 2022 yılındaki, Estonya'da ise 2022 ve 2024 yıllarındaki azalışlar sonrasında GSYH başına

düşen toplam iç ulaşım altyapı yatırımlarında 2025 yılında yükseliş yaşanacağı öngörülmüştür. Ekonomik büyüme ve artan uluslararası ticaret ise Türkiye’de iç ulaşım altyapı yatırımlarında artışa sebep olabilecek unsurlardır. ÇKA ile yapılan analizde son olarak ise; Avusturya, İrlanda, İtalya, Letonya, Litvanya, Lüksemburg, İsviçre, Türkiye ve Birleşik Krallık’ta özellikle Covid-19 salgını sonrasında artan hava trafiği ile bu ülkelerde 2025 yılında uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının artacağı öngörülmüştür. Tam tersine Avustralya, Estonya ve Norveç’te ise 2025 yılında uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının azalacağı öngörülmüştür. Analizin son adımında ise, demiryolu altyapı yatırımlarının, kişi başına düşen demiryolu altyapı yatırımlarının, GSYH başına düşen toplam iç ulaşım altyapı yatırımlarının ve uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının ekonomik büyümeye etkisi bir mikro panel uygulaması gerçekleştirilerek incelenmiştir. Regresyon analizi için dirençli bir tahminci olan Driscoll-Kraay tercih edilmiştir. OECD ülkelerinin 2010-2019 dönemini kapsayan yıllık verileri ile STATA 16 paket programında analizler gerçekleştirilmiştir. Regresyon analizi sonucunda ilk olarak, demiryolu altyapı yatırımı ve kişi başına düşen demiryolu altyapı yatırımının GSYH üzerindeki etkisinin istatistiki olarak anlamsız olduğu tespit edilmiştir. OECD ülkelerinin çoğunda demiryolu ağlarının mevcut ve iyi durumda olmasının yanı sıra uzun vadeli projeler olan demiryolu altyapı yatırımlarının ekonomik etkilerinin on yıllık bir süreçte ortaya çıkmadığı söylenebilir. Regresyon analizi sonucunda ikinci olarak; OECD ülkelerinde GSYH başına düşen toplam iç ulaşım altyapı yatırımının GSYH üzerinde istatistiki olarak anlamlı ve negatif bir etkiye sahip olduğu tespit edilmiştir. Öyle ki GSYH başına düşen toplam iç ulaşım altyapı yatırımında yaşanan %1’lik artışın GSYH’yı %0.115 azalttığı belirlenmiştir. Nitekim altyapı yatırımlarına ilişkin İyi planlama yapılmaması, mevcut kamu borçları ve yaşanan ekonomik krizler iç ulaşım altyapı yatırımlarının sebep olacağı ekonomik büyüme etkisinin ortaya çıkmamasına sebebiyet verebilmektedir. Regresyon analizinde üçüncü ve son olarak ise; uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payının GSYH üzerindeki etkisinin istatistiki olarak anlamlı ve pozitif olduğu belirlenmiştir. Bu kapsamda uluslararası havacılık sığınaklarından kaynaklanan CO₂ emisyonlarının toplam CO₂ emisyonları içerisindeki payında yaşanan %1’lik bir artışın GSYH’yı %0.544 arttırdığı tespit edilmiştir. OECD ülkelerinde uluslararası ticaret ve turizm faaliyetleri sebebi ile yoğun

olarak gerekleşen havayolu yk ve yolcu taşımacılıkları uluslararası hava trafiğine ve dolayış ile de emisyon salınımına sebebiyet vermektedir. Fakat aynı zamanda uluslararası ticaret ve turizm faaliyetleri sebebi ile artan hava trafiğı OECD lkelerinde ekonomik bymenin de nemli bir unsuru olarak karřımıza ıkmıřtır.



6. KAYNAKÇA

1. Abreu, L. R., Maciel, I. S. F., Alves, J. S., Braga, L. C., & Pontes, H. L. J. (2023). A decision tree model for the prediction of the stay time of ships in Brazilian ports. *Engineering Applications of Artificial Intelligence*, 117, 105634.
2. Ağbulut, Ü. (2022). Forecasting of transportation-related energy demand and CO₂ emissions in Turkey with different machine learning algorithms. *Sustainable Production and Consumption*, 29, 141–157.
3. Aggarwal, C. C. (2015). *Data Mining: the textbook*. Springer International Publishing.
4. Akçetin, E., Çelik, U., & Takçı, H. (2013). Lojistik ve denizcilik sektörü açısından veri madenciliği uygulamalarının önemi. *Journal of ETA Maritime Science*, 1(2), 73–80.
5. Aker, Ş. L., & Aghaei I. (2019). Comparison of business environments in oil-rich MENA countries: a clustering analysis of economic diversification and performance. *Emerging Markets Finance and Trade*, 55(12), 2871–2885.
6. Akgül, I. (2003). *Analysis of time series and ARIMA Models*. İstanbul: Der Yayınevi.
7. Akgüngör, A. P., & Demirel, A. (2004). Türkiye'deki ulaştırma sistemlerinin analizi ve ulaştırma politikaları. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 10(3), 423–430.
8. Akkuş, B., & Zontul, M. (2019). Veri madenciliği yöntemleri ile ülkeleri gelişmişlik ölçütlerine göre kümeleme üzerine bir uygulama. *AURUM Journal of Engineering Systems and Architecture*, 3(1), 51–64.
9. Akpınar, H. (2000). Veri tabanlarında bilgi keşfi ve veri madenciliği. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 29(1), 1–22.
10. Albayrak, A. S., & Koltan Yılmaz, Ş. (2009). Veri madenciliği: Karar ağacı algoritmaları ve İMKB verileri üzerine bir uygulama. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(1), 31–52.
11. Apurv, R., & Uzma, S. H. (2021). The impact of infrastructure investment and development on economic growth on BRICS. *Indian Growth and Development Review*, 14(1), 122–147.
12. Aytekin, A. (2019). *Mobilya endüstrisinde ihracat performansının belirleyicilerinin analizleri: bulanık AHP ve karar ağacı modellemesi* (Yayımlanmamış doktora tezi). Zonguldak Bülent Ecevit Üniversitesi, Sosyal Bilimler Enstitüsü, Zonguldak.
13. Badalyan, G., Herzfeld, T., & Rajcaniova, M. (2014). Transport infrastructure and economic growth: Panel data approach for Armenia, Georgia and Turkey. *Review of Agricultural and Applied Economics*, 17(2), 22–31.
14. Ballou, R. H. (2007). The evolution and future of logistics and supply chain management. *European Business Review*, 19(4), 332–348.
15. Baltagi, B. H. (2005). *Econometric Analysis of Panel Data*. John Wiley & Sons.
16. Bell, D. N., & Blanchflower, D. G. (2015). Youth unemployment in Greece: Measuring the challenge. *IZA Journal of European Labor Studies*, 4(1), 1–25.
17. Berry, M. J., & Linoff, G. (2004). *Data mining techniques: For marketing, sales, and customer relationship management*. John Wiley & Sons.
18. Billková, D. (2019). Assessment of living standard indicators in the OECD member countries. *ACC Journal*, 25(2), 21–45.
19. Born, B., & Breitung, J. (2015). Testing for serial correlation in fixed-effects panel data models. *Econometric Reviews*, 35(7), 1290–1316.

20. Bouckaert, E. E., Frank, E., Hall, M., Kirkby, R., Reutemann, P., Seewald, A., & Scuse, D. (2013). *WEKA manuel for versiyon 3-7-8*. University of Waikato.
21. Bovet, D. (1991). Logistics strategies for Europe in the nineties. *Planning Review*, 19(4), 12–48.
22. Bramer, M. (2020). *Principles of Data Mining*, Springer.
23. Breusch, T. S., & Pagan, A. R. (1980). The lagrange multiplier test and its applications to model specification in econometrics. *The Review of Economic Studies*, 47(1), 239–253.
24. Brzyska, J., & Szamrej-Baran, I. (2021). Classification of the EU countries according to the vulnerability of their economies to the impact of COVID-19 pandemic. *European Research Studies Journal*, XXIV, 967–978.
25. Cemaloğlu, N., & Duykuluoğlu, A. (2020). *Sosyal bilimlerde veri madenciliği*. Pegem Akademi.
26. Che, D., Safran, M., & Peng, Z. (2013). From big data to big data mining: Challenges, issues, and opportunities. In *Database System for Advanced Application: 18th International Conference, DASFAA, 7827 LNCS*, 1–15.
27. Chen, M. S., Han, J., & Yu, P. S. (1996). Data mining: an overview from a database perspective. *IEEE Transactions on Knowledge and Data Engineering*, 8(6), 866–883.
28. Chudik, A., & Pesaran, M. H. (2013). Large panel data models with cross-sectional dependence: A survey. *Center for Applied Financial Economics (CAFE)*, 1-54.
29. Çılgın, C., & Kurt, A. S. (2021). Dış ticaret verileri için kümeleme analizi: Türkiye, Azerbaycan ve Kazakistan örneği. *Sosyoekonomi*, 29(48), 511–540.
30. Collier, K., Carey, B., Grusy, E., Marjaniemi, C., & Sautter, D. (1998). A perspective on data mining. *Centre for Data Insight, Northern Arizona University, USA*, 2–39.
31. Cooper, M. C., Lambert, D. M., & Pagh, J. D. (1997). Supply chain management: More than a new name for logistics. *The International Journal of Logistics Management*, 8(1), 1–14.
32. Cox, M., & Ellsworth, D. (1997). Application-controlled demand paging for out-of-core visualization. In *Proceedings. Visualization'97 (Cat. No. 97CB36155)*. IEEE., 235–244.
33. Daniela, N. I., & Oradea, R. (2014). Why do logistics and transport matter for development. *The Annals of The University of Oradea*, 33–38.
34. De Oña, J., De Oña, R., & Calvo, F. J. (2012). A classification tree approach to identify key factors of transit service quality. *Expert Systems with Applications*, 39(12), 11164–11171.
35. Demir, A. S., & Eminler, Ö. E. (2020). Estimation of CO₂ emissions from air transportation in EU countries by artificial neural networks. *International Journal of Global Warming*, 21(3), 234–243.
36. Demirkale Ö, & Özarı Ç. (2020). K-ortalamalar kümeleme yöntemi ile temel makroekonomik ve finansal göstergeler ile değerlendirilmesi: Kırılgan beşli ülkelerinin örneği. *Finans Ekonomi ve Sosyal Araştırmalar Dergisi*, 5(1), 22–32.
37. Devlin, J., & Yee, P. (2005). Trade logistics in developing countries: The case of the middle east and north Africa. *World Economy*, 28(3), 435–456.
38. Driscoll, J. C., & Kraay, A. C. (1998). Consistent covariance matrix estimation with spatially dependent panel data. *The Review of Economics and Statistics*, 80(4), 549–560.

39. Erdoğan, H. T. (2016). Ulaşım hizmetlerinin ekonomik kalkınma üzerine etkisi. *Istanbul Gelisim University Journal of Social Sciences*, 3(1), 187–215.
40. Erkan, B. (2014). Türkiye’de lojistik sektörü ve rekabet gücü. *ASSAM Uluslararası Hakemli Dergi*, 1(1), 44–65.
41. Ersöz, F. (2019). *Veri madenciliği teknikleri ve uygulamaları*. Seçkin Kitabevi.
42. Erturgut, R. (2016). *Lojistik ve tedarik zinciri yönetimi*. Nobel Akademik Yayıncılık.
43. Everitt, B. (1974). *Cluster analysis*. Heinemann Educational Books.
44. Farris, M. T. (1997). Evolution of academic concerns with transportation and logistics. *Transportation Journal*, 37(1), 42–50.
45. Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). From data mining to knowledge discovery in databases. *AI Magazine*, 17(3), 37–54.
46. Gani, A. (2017). The logistics performance effect in international trade. *The Asian Journal of Shipping and Logistics*, 33(4), 279–288.
47. Gatarić, D., Ruškić, N., Aleksić, B., Đurić, T., Pezo, L., Lončar, B., & Pezo, M. (2023). Predicting road traffic accidents—artificial neural network approach. *Algorithms*, 16(5), 257.
48. Gera, M., & Goel, S. (2015). Data mining-techniques, methods and algorithms: A review on tools and their validity. *International Journal of Computer Applications*, 113(18), 975–8887.
49. Gherghina, Ş. C., Onofrei, M., Vintilă, G., & Armeanu, D. Ş. (2018). Empirical evidence from EU-28 countries on resilient transport infrastructure systems and sustainable economic growth. *Sustainability*, 10(8), 1–34.
50. Goebel, M., & Gruenwald, L. (1999). A survey of data mining and knowledge discovery software tools. *ACM SIGKDD Explorations Newsletter*, 1(1), 20–33.
51. Gorunescu, F. (2011). *Data mining: Concepts, models and techniques* (Vol. 12). Springer Science & Business Media.
52. Gosasang, V., Chandraprakaikul, W., & Kiattisin, S. (2011). A comparison of traditional and neural networks forecasting techniques for container throughput at bangkok port. *The Asian Journal of Shipping and Logistics*, 27(3), 463–482.
53. Grabmeier, J., & Rudolph, A. (2002). Techniques of cluster algorithms in data mining. *Data Mining and Knowledge Discovery*, 6(4), 303–360.
54. Grădinaru, G. I., & Maricuţ, A. C. (2022). From the rebound effect to the perspective of circular economy: A structure changes analysis among EU countries. *Economic Computation & Economic Cybernetics Studies & Research*, 56(1), 257–272.
55. Greene, W. H. (2000). Econometric analysis (4th ed.). *International Edition*, New Jersey: Prentice Hall.
56. Greene, W. H. (2003). *Econometric Analysis*. Pretence Hall.
57. Gülpınar, V. (2008). *Avrupa birliği ülkeleri ile Türkiye’nin ekonomik göstergelerinin karar ağacı yöntemi ile karşılaştırılması* (Yayımlanmamış yüksek lisans tezi). Marmara Üniversitesi, Sosyal Bilimler Enstitüsü, İstanbul.
58. Hamzaçebi, C. (2011). *Yapay sinir ağları tahmin: Tahmin amaçlı kullanımı MATLAB ve Neurosolutions uygulamalı*. Ekin Yayınevi.
59. Han, J., Kamber, M., & Pei, J. (2012). *Data mining concepts and techniques* (3rd ed.). Morgan Kaufman.
60. Hand, D. J. (1998). Data mining: Statistics and more? *The American Statistician*, 52(2), 112–118.
61. Hausman, J. A. (1978). Specification tests in econometrics. *Econometrica*, 46(6), 1251–1271.

62. Hayaloğlu, P. (2015). The impact of developments in the logistics sector on economic growth: The case of OECD countries. *International Journal of Economics and Financial Issues*, 5(2), 523–530.
63. Haykin, S. (2009). *Neural networks and learning machines* (3rd ed.). Prentice Hall/Pearson.
64. Hesse, M., & Rodrigue, J. P. (2004). The transport geography of logistics and freight distribution. *Journal of Transport Geography*, 12(3), 171–184.
65. Holsheimer, M., Kersten, M. L., Mannila, H., & Toivonen, H. (1995). A perspective on databases and data mining. *KDD*, 95, 150–155.
66. Islam, M. K., Dalhat, M. A., & Al Mamun, A. (2022). Road infrastructure investment limits based on minimal accidents using artificial neural network. *Applied Sciences*, 12(23), 1-20.
67. İşleyen, Ş. (2021). Clustering analysis of employment sectors according to OECD countries using the k-average method. *International Journal of Contemporary Economics and Administrative Sciences*, 11(1), 93–105.
68. Işık, M., & Çamurcu, A. Y. (2007). K-means, k-medoids ve bulanık c-means algoritmalarının uygulamalı olarak performanslarının tespiti. *İstanbul Ticaret Üniversitesi Fen Bilimleri Dergisi*, 6(11), 31–45.
69. Jamil, A., Abdullah, M., Javed, M. A., & Hassan, M. S. (2018). Comprehensive review of challenges & technologies for big data analytics. *International Conference on Computer and Communication (CCET)*, 229–233.
70. Jena, P. R., Managi, S., & Majhi, B. (2021). Forecasting the CO₂ emissions at the global level: A multilayer artificial neural network modelling. *Energies*, 14(19), 1-23.
71. Kabaklarlı, E., Mangır, F., & Ayhan, F. (2018). Ulaştırma altyapı yatırımlarının ekonomik büyümeye katkısı: Seçilmiş ülkeler için panel eşbütünleşme analizi. *Anemon Muş Alparslan Üniversitesi Sosyal Bilimler Dergisi 6(ICEESS'18)*, 6, 303–309.
72. Kara, M. A., & Cığırlioğlu, O. (2018). Türkiye ekonomisinde ulaşım altyapısının ekonomik büyümeye etkisi. *Gaziantep Üniversitesi Sosyal Bilimler Dergisi*, 17(2), 577–591.
73. Kara, M., Tayfur, L., & Basık, H. (2009). Küresel ticarete lojistik üslerin önemi ve Türkiye. *Mustafa Kemal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 6(11), 69–84.
74. Karakurt, I., & Aydin, G. (2023). Development of regression models to forecast the CO₂ emissions from fossil fuels in the BRICS and MINT countries. *Energy*, 14(6336), 1-23.
75. Katal, A., Wazid, M., & Goudar, R. H. (2013). Big data: Issues, challenges, tools and good practices. *2013 Sixth International Conference on Contemporary Computing (IC3)*, 404–409.
76. Kaya, M., & Özel, S. A. (2014). Açık kaynak kodlu veri madenciliği yazılımlarının karşılaştırılması. *Akademik Bilişim*, 47–53.
77. Kayakuş, M., & Terzioğlu, M. (2021). Yapay sinir ağları ve çoklu doğrusal regresyon kullanarak emeklilik fonu net varlık değerlerinin tahmin edilmesi. *Bilişim Teknolojileri Dergisi*, 14(1), 95–103.
78. Khan, M. A., Uddin, M. F., & Gupta, N. (2014). Seven V's of big data understanding big data to extract value. *Proceedings of the 2014 Zone 1 Conference of the American Society for Engineering Education*. 1–5.

79. Kılınç, G., Karaatlı, M., & Ömürbek, N. (2022). Türkiye limanlarındaki konteyner ve yük elleçleme hacimlerinin ysa narx modeli ile öngörülmesi. *Journal of Productivity*, 2, 251–266.
80. Koban, E., & Yıldırım Keser, H. (2021). *Dış ticarete lojistik*. Ekin Basım Yayın Dağıtım.
81. Koldere Akın, Y. (2022). *Veri madenciliğinde kümeleme algoritmaları ve kümeleme analizi*. Gazi Kitabevi.
82. Kubat, C. (2015). *Matlab yapay zeka ve mühendislik uygulamaları* (1st ed.). Abaküs Kitap Yayın Pazarlama.
83. Küçük, B. (2022). *Türkiye’de lojistik faaliyetlerin bölgesel kalkınma açısından önemi*. Akademisyen Kitabevi.
84. Kutnjak, A., Hrustek, L., & Krizanic, S. (2020). Applying the decision tree method in identifying key indicators of the digital economy and society index (DESI). In *2020 43rd International Convention on Information, Communication and Electronic Technology (MIPRO)*, 1312–1317.
85. Laney, D. (2001). 3D data management: Controlling data volume, velocity and variety. *Application Delivery Strategies by META Group Inc.*
86. Larose, D. T., & Larose, C. D. (2014). *Discovering knowledge in data: An introduction to data mining* (Vol. 4). John Wiley & Sons.
87. Lee, I. (2017). Big data: Dimensions, evolution, impacts, and challenges. *Business Horizons*, 60(3), 293–303.
88. Lewis, C. D. (1982). *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting*. Butterworths Publishing.
89. Lippmann, R. P. (1988). An introduction to computing with neural nets. *ACM SIGARCH Computer Architecture News*, 16(1), 7–25.
90. Long, D. (2019). *Uluslararası lojistik, küresel tedarik zinciri yöntemi*. Nobel Akademik Yayıncılık.
91. Long, J. S., & Ervin, L. H. (2000). Using heteroscedasticity consistent standard errors in the linear regression model. *American Statistician*, 54(3), 217–224.
92. MacQueen, J. (1967). Some methods for classification and analysis of multivariate observations. *Proceedings of the Fifth Berkeley Symposium on Mathematical*, 281–297.
93. Magee, J. F., Copacino, W. C., & Rosenfield, D. B. (1985). *Modern logistics management: Integrating marketing, manufacturing, and physical distribution* (Vol. 22). John Wiley & Sons.
94. Maheshwari, A. K. (2015). *Business intelligence and data mining* (M. Ferguson, Ed.). Business Expert Press.
95. Mangan, J., & Lalwani, C. (2016). *Global logistics and supply chain management*. Wiley & Sons.
96. Marčeta, M., & Boinec, S. (2022). Analysis of the economic performance and competitiveness of the European Union countries. *Serbian Journal of Management*, 17(1), 219–236.
97. Megyesiova, S., & Lieskovska, V. (2018). Analysis of the sustainable development indicators in the OECD countries. *Sustainability*, 10(2), 1–23.
98. Mijwel, M. M. (2017). Yapay sinir ağlar yapısı ve fonksiyonu. *Bilgisayar Bilimleri, Bilimleri Koleji*, 1–4.
99. Mints, A. (2017). Classification of tasks of data mining and data processing in the economy. *Baltic Journal of Economic Studies*, 3(3), 47–52.
100. Moulton, B., & Randolph, R. C. (1989). Alternative tests of the error components model. *Econometrica: Journal of the Econometric Society*, 57(3), 685–693.

101. Murphy, P. R., & Wood, D. (2015). *Contemporary Logistics*. Pearson.
102. Mutascu, M. (2022). CO₂ emissions in the USA: New insights based on ANN approach. *Environmental Science and Pollution Research*, 29(45), 68332–68356.
103. Naik, K., & Joshi, A. (2017). Role of big data in various sectors. *International Conference on I-SMAC*, (2017), 117–122.
104. Navickas, V., Sujeta, L., & Vojtovich, S. (2011). Logistics systems as a factor of country's competitiveness. *Economics and Management*, 16, 231–237.
105. Ohlhorst, F. (2012). *Big data analytics: turning big data into big money* (Vol. 65). John Wiley & Sons.
106. Orhan, O. Z. (2014). *Dünya'da ve Türkiye'de lojistik sektörünün gelişimi*. İstanbul Gelişim Üniversitesi Yayınları.
107. Özdemir, Ü. (2021). Model Proposal for future estimates in maritime industry: The case of container handling in Turkish ports. *Journal of ETA Maritime Science*, 9(1), 13–21.
108. Özkan, B., Parim, C., & Çene, E. (2023). Ülkelerin gelişmişlik düzeylerinin karar ağacı ve rastgele orman yöntemleriyle tahmin edilmesi. *EKOIST Journal of Econometrics and Statistics*, 38, 87–104.
109. Özkan, Y. (2020). *Veri madenciliği yöntemleri*. Papatya Yayıncılık.
110. Öztemel, E. (2006). *Yapay sinir ağları* (2nd ed.). Papatya Yayıncılık.
111. Pesaran, M. H. (2004). General diagnostic tests for cross section dependence in panels. Cambridge Working Papers. *Economics*, 1240(1), 1–17.
112. Pilipczuk, O., Cosenco, N., & Kosenko, O. (2019). Big data: Challenges and opportunities in financial management. *Problemy Zarzadzania*, 17(85), 9–23.
113. Polat, H. (2021). *Halkla ilişkiler 2.0 kapsamında hedef belirleme ve ölçme sorunsalına bakış: Alternatif bir yöntem olarak veri madenciliğinin kullanılmasına yönelik örnek bir uygulama* (Yayımlanmamış doktora tezi). Atatürk Üniversitesi, Sosyal Bilimler Enstitüsü, Erzurum.
114. Pradhan, R. P., Arvin, M. B., & Nair, M. (2021). Urbanization, transportation infrastructure, ICT, and economic growth: A temporal causal analysis. *Cities*, 115, 103213.
115. Pujari, A. K. (2001). *Data mining techniques*. Universities Press.
116. Pujari, A. K., Rajesh, K., & Reddy, D. S. (2001). Clustering techniques in datamining—a survey. *IETE Journal of Research*, 47(1–2), 19–28.
117. Ramageri, B. M. (2010). Data mining techniques and applications. *Indian Journal of Computer Science and Engineering*, 1(4), 301–305.
118. Russell, S. H. (2000). Growing world of logistics. *Air Force Journal of Logistics*, 24(4), 12–17.
119. Rygielski, C., Wang, J. C., & Yen, D. C. (2002). Data mining techniques for customer relationship management. *Technology in Society*, 24(4), 483–502.
120. Saeed, N., & Cullinane, K. (2021). Identifying the characteristics of China's maritime trading partners on the basis of bilateral shipping connectivity: A cluster analysis. *Maritime Policy & Management*, 50(1), 42–57.
121. Saidi, S., & Hammami, S. (2011). The role of transport and logistics to attract foreign direct investment in the developing countries. *4th International Conference on Logistics, LOGISTIQUA'2011*, 484–489.
122. Samir, S., & Mefteh, H. (2020). Empirical analysis of the dynamic relationships between transport, ICT and FDI in 63 countries. *International Economic Journal*, 34(3), 448–471.

- 123.Şen, H., Yaşayanlar, A., & Denizhan, B. (2021). Türkiye’de limanlarda yük taşımacılığı veri analizi. *European Journal of Science and Technology*, 22, 436–444.
- 124.Şen, S., Yilmaz, T., (2023). Altyapı ve iktisadi büyüme ilişkisi üzerine ekonometrik bir analiz. *Journal of Economic Policy Researches*, 10(2), 361–393.
- 125.Shalabi, L. Al, Shaaban, Z., & Science, B. K. (2006). Data mining: A preprocessing engine. *Journal of Computer Science*, 2(9), 735–739.
- 126.Sing, A., & Mishra, G. C. (2015). Application of Box-Jenkins method and Artificial Neural Network procedure for time series Forecasting of Prices. *Statistics in Transition. New Series*, 16(1), 83–96.
- 127.Singh, N., Raw, R. S., & Chauhan, R. K. (2012). Data mining with regression technique. *Journal of Information Systems and Communication*, 3(1), 199-211.
- 128.Sönmez Çakır, F. (2020). *Yapay sinir ağları-MATLAB kodları ve MATLAB toolbox çözümleri* (3rd ed.). Nobel.
- 129.Sowmya, R., & Suneetha, K. R. (2017). Data mining with big data. *11th International Conference on Intelligent Systems and Control (ISCO). IEEE*, 246–250.
- 130.Suhányi, L., Suhányiová, A., Koreckova J, Bednarova, L., Kadarova, J., Derkawi H, & Bacova K. (2021). Relations between the inflow of foreign direct investments and economic indicators in OECD countries. *Acta Montanistica Slovaca*, 24(4), 810–824.
- 131.Taft, M., Krishnan, R., Hornick, M., Mukhin, D., Tang, G., Thomas, S., Berger, C., Campos, M., Milenova, B., Tamayo, P., Abeles, G., Yarmus, J., & Venkayala, S. (2003). *Data Mining*. Oracle.
- 132.Takçı, H. (2020). *Teori ve uygulamada veri madenciliği*. Nobel Akademik Yayıncılık.
- 133.Taylor-Sakya, K. (2016). Big data: Understanding big data. *Cornell University*. <https://arxiv.org/abs/1601.04602>, (Erişim tarihi:14.11.2025)
- 134.Tekerek, A. (2011). Data Mining processes and open-source data mining tools. *Akademik Bilişim*, 161–169.
- 135.Teksin, G. G., & Turanlı, M. (2018). Classification of household users using information technologies based on C5. 0 algorithm. *Eurasian Journal of Business and Management*, 6(2), 33–47.
- 136.Timor, M., & Yüzbaşı Künc, G. (2021). Ekonomik gelişmişliği etkileyen bilgi ekonomisi değişkenlerinin veri madenciliği ile belirlenmesi. *Optimum Ekonomi ve Yönetim Bilimleri Dergisi*, 8(1), 1–18.
- 137.Tseng, Y. Y., Yue, W. L., & Taylor, M. A. (2005). The role of transportation in logistics chain. *Eastern Asia Society for Transportation Studies*, 5, 1657–1672.
- 138.Turanlı, M., Özden, Ü. H., & Türedi, S. (2006). Avrupa Birliği’ne aday ve üye ülkelerin ekonomik benzerliklerinin kümeleme analiziyle incelenmesi. *İstanbul Ticaret Üniversitesi Sosyal Bilimler Dergisi*, 5(9), 95–108.
- 139.Voortman, C. (2004). *Global logistics management*. Juta Academics.
- 140.Wang, C., Lim, M. K., Zhang, X., Zhao, L., & Lee, P. T. W. (2020). Railway and road infrastructure in the Belt and Road Initiative countries: Estimating the impact of transport infrastructure on economic growth. *Transportation Research Part A: Policy and Practice*, 134, 288–307.
- 141.Wang, L., Xue, X., Zhao, Z., & Wang, Z. (2018). The impacts of transportation infrastructure on sustainable development: Emerging trends and challenges. *International Journal of Environmental Research and Public Health*, 15(6), 1172–1191.

142. Waters, D. (2021). *Logistics: An introduction to supply chain management*. Palgrave Macmillan.
143. Williams, G. (2011). *Data mining with Rattle and R: The art of excavating data for knowledge discovery*. Springer Science & Business Media.
144. Witten, I. H., Frank, E., Hall, M. A., & Pal, C. J. (2016). Practical machine learning tools and techniques. In *doc1.bibliothek.li* (3rd ed.). Morgan Kaufmann.
145. Wu, X., Liu, J., Jin, H., & Guo, L. (2012). The design and analysis of logistics information system based on data mining. *Lecture Notes in Electrical Engineering*, 173 LNEE (2), 67–74.
146. Yakut, E., & Korkmaz, A. (2020). İnsani gelişmişlik endeksinin karar ağacı algoritmaları ile modellenmesi: BM’de bir uygulama 2010-2017 dönemi. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 20(2), 65–84.
147. Yavuz, S., & Deveci, M. (2012). İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167–187.
148. Yerdelen Tatoğlu, F. (2021). *Panel veri ekonometrisi Stata uygulamalı* (6th ed.). Beta Basım Yayın Dağıtım.
149. Yurtoğlu, H. (2005). *Yapay sinir ağları metodolojisi ile öngörü modellemesi: Bazı makroekonomik değişkenler için Türkiye örneği* (Yayınlanmamış uzmanlık tezi). Devlet Planlama Teşkilatı, Ekonomik Modeller ve Stratejik Araştırmalar Genel Müdürlüğü, Ankara.
150. Yüzbaşı Künc, G. (2018). Avrupa birliği ülkeleri ve Türkiye’nin 2013-2017 yıllarına ait ekonomik göstergelerinin kümeleme analizi ile değerlendirilmesi. *Atlas Journal*, 4(15), 1676–1684.
151. Zaki, M. J., & Wong, L. (2003). Data mining techniques. *WSPC/Lecture Notes Series*, 9, 1-40.
152. Zheng, Q. Y., Law, T. H., Wong, S. V., & Ng, C. P. (2024). Relative improvements between roads and railways and economic performance: A panel data analysis. *Transport Policy*, 153, 87–96.
153. <https://stats.oecd.org/> (Erişim tarihi: 10.06.2023-20.09.2023).
154. <https://data.worldbank.org/> (Erişim tarihi: 10.06.2023).
155. <https://www.cs.waikato.ac.nz/ml/weka/> (Erişim tarihi: 12.03.2023).
156. <https://cscmp.org/> (Erişim tarihi: 26.03.2023).
157. <https://www.weforum.org/stories/2020/01/italy-economy-growth-instability-exports/> (Erişim tarihi: 05.03.2025).
158. <https://data-explorer.oecd.org/> (Erişim Tarihi: 23.06.2025).
159. <https://ec.europa.eu/> (Erişim Tarihi: 23.06.2025).
160. <https://tr.tradingeconomics.com/> (Erişim Tarihi: 23.06.2025).
161. <https://aviationbenefits.org/other-environmental-challenges/climate-action/market-based-measures/corsia/corsia-explained/> (Erişim tarihi: 20.10.2025).
162. https://climate.ec.europa.eu/eu-action/transport-decarbonisation/reducing-emissions-aviation_en (Erişim tarihi: 20.10.2025).
163. <https://www.ab.gov.tr/p.php?e=92> (Erişim tarihi: 20.10.2025).
164. <https://ticaret.gov.tr/dis-iliskiler/yesil-mutabakat/ab-sinirda-karbon-duzenleme-mekanizmasi/ab-skdm-bilgi-notu> (Erişim tarihi: 20.10.2025).
165. https://www.eeas.europa.eu/sites/default/files/documents/brochure_3_v2.pdf (Erişim tarihi: 20.10.2025).
166. <https://yesilbuyume.org/corsia-nedir/> (Erişim tarihi: 20.10.2025).

- 167.(https://ec.europa.eu/eurostat/databrowser/view/rail_if_line_ga/default/table?lang=en&category=rail.rail_if (Eriřim tarihi: 26.08.2025)).
- 168.<https://www.oecd.org/content/dam/oecd/en/events/2025/05/ministerial-meeting-on-regional-development-policy/kip-rdpc-ministerial-meeting-2025.pdf> Eriřim Tarihi: 30.10.2025).
- 169.(<https://www.undp.org/sustainable-development-goals> (Eriřim tarihi: 02.11.2025))



ÖZGEÇMİŞ

Adı Soyadı: Burcu YAMAN SELÇİ

Eğitim Geçmişi:

2013-2017: Akdeniz Üniversitesi Alanya İşletme Fakültesi Ekonomi ve Finans Lisans Programı.

2017-2019: Alanya Alaaddin Keykubat Üniversitesi Sosyal Bilimler Enstitüsü Uluslararası Ticaret Anabilim Dalı Yüksek Lisans Programı.

2019-2025 : Alanya Alaaddin Keykubat Üniversitesi Lisansüstü Eğitim Enstitüsü Uluslararası Ticaret Anabilim Dalı Doktora Programı.

Mesleki Geçmişi:

2021-.....: Pamukkale Üniversitesi Denizli Sosyal Bilimler MYO – Dış Ticaret Bölümü Öğretim Görevlisi.

Yayınlar ve Bilimsel Faaliyetler:

Yaman Selçi, B., Geçgil G.& Yavuz G. (2018). Elektronik ticaret ve mobil ticaret üzerine bir inceleme: Meta-analiz çalışması. *Research Studies Anatolia Journal*, 1(2), 142-153., Doi: 10.33723/rs.428407.

Akgül, Y., Yaman Selçi, B., Geçgil, G., & Yavuz, G. (2019). The influencing factors for purchasing intentions in social media by utaut perspective. *In Structural equation modeling approaches to e-service adoption* (pp. 254-267). IGI Global.

Akgül, Y., Yaman Selçi, B., Geçgil, G., Yavuz G. (2020). Yenilik ekonomisi üzerine bibliyometrik bir inceleme. *The Journal of International Lingual Social and Educational Sciences*, 6(1), 66-81. <https://doi.org/10.34137/jilses.565275>

Yaman Selçi B. ve Akgül Y. (2020), Türkiye'nin ihracat değerlerinin yapay sinir ağları ile tahmini üzerine bir inceleme, *Nicel Bilimler Dergisi*, 2(2), 29-42.

Yaman Selçi, B. (2021). Türkiye'nin konut satışı değerlerinin yapay sinir ağları ile öngörülmesi. *EKOIST Journal of Econometrics and Statistics*, (35), 19-32. <https://doi.org/10.26650/ekoist.2021.35.180033>

Yaman Selçi, B. (2022). Turizm ekonomisi alanındaki lisansüstü tezlerin bibliyometrik analizi (1988-2021). *Uluslararası Türk Dünyası turizm, ekonomi ve kültürel miras sempozyumu; 23-24 Haziran 2022; Denizli*.

Dursun, M. T. & Yaman Selçi B. (2022). Uluslararası Türk dünyası turizm, ekonomi ve kültürel miras sempozyumu. *Anatolia: Turizm Araştırmaları Dergisi*, 33(3), 161-162. Doi: 10.17123/atad.1186696

Yaman Selçi, B. & Geçgil, G. (2023). İyisiyle kötüsüyle sürdürülebilirlik yaşasın iyilik. Lojistikte sürdürülebilirlik (pp. 247- 264). Nobel Bilimsel.

