

Çekim Modeli Çerçevesinde Ticaret Tahmininde Makine Öğrenmesi Yöntemlerinin Performans Karşılaştırması: Türkiye ve Türk Cumhuriyetleri Örneği

Ahmet AY *

Haldun SOYDAL **

Mustafa AY ***

ÖZ

Bu çalışmada, Türkiye'nin Türk Cumhuriyetleri (Azerbaycan, Kazakistan, Kırgızistan, Özbekistan ve Türkmenistan) ile olan ticaret hacmi çekim modeli kullanılarak analiz edilmiş ve 2024-2025 yılları için Türkiye ile bu ülkeler arasındaki ticaret hacmini tahmin etmede en başarılı makine öğrenimi yöntemi belirlenmek istenmiştir. Bu amaçla çalışmada Türk Cumhuriyetlerinin bağımsızlıklarını kazandıkları 1992 yılından başlayarak 2023 yılına kadar olan veriler kullanılmıştır. Bu veriler sayısal değişkenler olarak Türkiye ile Türk Cumhuriyetleri arasındaki ihracat ve ithalat verileri, ülkelerin milli gelirleri, aralarındaki mesafe; kukla değişkenler olarak ise ülkelerin birbirleriyle olan sınırı, ortak dil, ülkelerin karayla çevriliilik durumu ve Dünya Ticaret Örgütü (DTÖ) üyelikleridir. Bu veriler, ticaret hacmini tahmin etmek için Lineer Regresyon, Gauss Süreç Regresyonu ve Çok Katmanlı Algılayıcılar gibi farklı makine öğrenmesi modelleri ile analiz edilmiştir. Uygulanan makine öğrenmesi modellerinin başarısı MAPE (Ortalama Mutlak Yüzde Hata) değerleri üzerinden kıyaslanmıştır. Analiz sonuçları, Çok Katmanlı Algılayıcılar modelinin en doğru tahminleri sağladığını ortaya koymuştur. Bu durum, ileri düzey makine öğrenmesi yöntemlerinin karmaşık ticaret dinamiklerini anlamada ve gelecekteki ticaret eğilimlerini öngörmede ne kadar etkili olabileceğini göstermektedir. Türkiye ve Türk Cumhuriyetleri arasındaki ticaret ilişkilerinin daha iyi anlaşılması ve bu ilişkilerin gelecekteki seyrinin tahmin edilmesi, bölgesel ekonomik politikaların oluşturulmasında önemli katkılar sağlayacaktır. Çalışma, bu ülkelerle olan ticaretin gelişimine yönelik stratejilerin belirlenmesi açısından da önemlidir.

Anahtar Kelimeler: Çekim Modeli, Çok Katmanlı Algılayıcılar, Gauss Süreç Regresyonu, Makine Öğrenmesi, Türk Cumhuriyetleri.

JEL Sınıflandırması: C51, C53, F17

* Prof. Dr., Selçuk Üniversitesi İktisadi ve İdari Bilimler Fakültesi, İktisat Bölümü, ahmetay@selcuk.edu.tr, ORCID Bilgisi: 0000-0002-6763-9568

** Prof. Dr., Selçuk Üniversitesi İktisadi ve İdari Bilimler Fakültesi, İktisat Bölümü, hsoydal@selcuk.edu.tr, ORCID Bilgisi: 0000-0001-6979-0256

*** Arş. Gör., Selçuk Üniversitesi İktisadi ve İdari Bilimler Fakültesi, İktisat Bölümü, mustafa.ay@selcuk.edu.tr, ORCID Bilgisi: 0000-0001-8635-6101

Performance Comparison of Machine Learning Methods in Trade Forecasting within the Framework of the Gravity Model: The Case of Turkey and the Turkic Republics

ABSTRACT

This study aims to analyze Turkey's trade volume with the Turkic Republics (Azerbaijan, Kazakhstan, Kyrgyzstan, Uzbekistan, and Turkmenistan) within the framework of the international trade gravity model and to predict the trade volume with these countries for the years 2024 and 2025. Export and import data between Turkey and the Turkic Republics from 1992 to 2023 were used, with countries' GDPs and distances as numerical variables, and border, language, landlocked status, and World Trade Organization (WTO) memberships as dummy variables. These data were processed using different machine learning models, including Linear Regression, Gaussian Process Regression, and Multilayer Perceptron, to predict trade volumes. The success of the applied machine learning models was compared based on MAPE (Mean Absolute Percentage Error) values. The analysis results indicated that the Multilayer Perceptron model provided the most accurate predictions. This finding demonstrates the effectiveness of advanced machine learning methods in understanding complex trade dynamics and forecasting future trade trends. A better understanding of trade relations between Turkey and the Turkic Republics and predicting the future trajectory of these relations will significantly contribute to the formulation of regional economic policies. The study also provides valuable insights for developing strategies to enhance trade with these countries.

Key Words: *Gaussian Process Regression, Gravity Model, Machine Learning, Multilayer Perceptron, Turkic Republics.*

JEL Classification: *C51, C53, F17*

GİRİŞ

Yapay zekâ 1950'lerde ortaya çıkmış ve günümüzde insan yaşamının hemen hemen her alanında uygulamalara sahip çok disiplinli bir alan hâline gelmiştir. Makine öğrenimi, bilgisayarları örnek veriler veya geçmiş deneyimler arasındaki örüntüyü tespit etmek amacıyla belirli bir performans kriterini gerçekleştirecek şekilde programlamaktır. Bu süreçte makine öğrenimi, geleceğe yönelik tahminler yapmak veya verilerden bilgi edinmek için kullanılabilir ya da her iki amacı da taşıyabilir (Alpaydin, 2014; Kulkarni & More, 2016).

Makine öğreniminin ekonomi alanında iki amaca da yönelik birçok örnek uygulaması vardır. Bunlardan biri, birçok ülke için önemli bir araç olan makroekonomik değişkenlerin tahmin edilmesidir. Yapay zekâ ve makine öğreniminin uluslararası makroekonomi ve ticaret için önemli bir araç olduğu kabul edilmektedir (Goldfarb & Trefler, 2018). Dolayısıyla yapay zekâ ve makine öğrenimi uluslararası ticaretin tahmin edilmesinde de kullanılmaktadır. Türkiye için bu alandaki öncü çalışma, büyük ticaret ortakları ile ikili ticaret akışlarını analiz eden Nuroğlu (2012) tarafından yapılmıştır. Çalışmada 1985'ten 2010'a kadar yıllık veriler kullanılarak panel veri modelleri ve sinir ağları kullanılmış ve sonuçlara göre Türkiye'nin ikili ticaret akışları analizinde sinir ağları, geleneksel panel veri modellerine göre üstünlük göstermiştir.

Bu çalışma Türkiye ile Türk Cumhuriyetleri arasında ikili dış ticaret akışlarını tahmin etmede makine öğrenimi algoritmalarının performansını değerlendirmeyi amaçlamaktadır. Analizdeki girdi değişkenleri, ihracatçı GSYİH'si, ithalatçı GSYİH'si, mesafe ve kukla değişkenler (Dil, Sınır, Karayla çevrili olma ve DTÖ) iken, çıktı değişkenleri ithalat ve ihracat değerleridir. Veriler

Türk Cumhuriyetlerinin bağımsızlığını kazandığı 1992 yılı ile 2023 yılı arasındaki dönem için toplanmış ve Türkiye'nin ikili ticaret akışlarını iki yıllık bir dönem için (2024 ve 2025 yılları) tahmin etmek amacıyla kullanılmıştır.

Tahmin algoritmalarının doğruluğu, ortalama mutlak yüzde hata (MAPE) hesaplanarak incelenmiştir. Beklenen sonuç, Türkiye ikili ticaret akışlarını tahmin etmede makine öğrenimi algoritmalarının iyi bir öngörü kapasitesine sahip olmasıdır. Bu durumdan hareketle çalışmanın hipotezi, gelişmiş makine öğrenimi algoritmalarının Türkiye'nin Türk Cumhuriyetleri ile ikili ticaretini tahmin etmede iyi bir öngörü kapasitesine sahip olacaktır. Çalışma, Türkiye örneğinde ikili ticaret akışlarını tahmin etmede üç farklı makine öğrenimi algoritmasını kullanarak mevcut duruma katkıda bulunmaktadır.

Çalışma giriş, teorik çerçeve, Türkiye'nin ticaret akışı ve örnek ülkeler ile ikili ticareti, yöntemlerin tanıtılması, bu yöntemlerle yapılan analizlerin bulguları ve sonuç şeklindedir altı bölümden oluşmaktadır.

I. TEORİK ÇERÇEVE

Uluslararası ticaret çekim modeli, uluslararası ticaretin analizinde yaygın olarak kullanılan ve Newton'un kütle çekim yasasından esinlenmiş bir modeldir. Bu model, iki ülke arasındaki ticaret hacminin, ülkelerin ekonomik büyüklükleri ile doğru orantılı, aralarındaki mesafe ile ters orantılı olduğunu öne sürer. İlk olarak Tinbergen (1962) ve Pöyhönen (1963) tarafından tanıtılan model, o tarihten bu yana ticaret akımlarının anlaşılması için temel bir araç haline gelmiştir.

Çekim modeli, ülkelerin ekonomik büyüklüklerini Gayri Safi Yurtiçi Hasıla (GSYİH) veya Gayri Safi Milli Hasıla (GSMH) ile ölçmektedir. Ekonomik büyüklük, bir ülkenin üretim kapasitesi ve tüketim potansiyelinin bir göstergesi olarak kabul edilmektedir. Daha büyük ekonomiler, daha fazla mal ve hizmet üretebilme ve tüketebilme kapasitesine sahip oldukları için, ticaret hacimlerinin de büyük olması beklenmektedir (Bergstrand, 1985).

Modelde mesafe, iki ülke arasındaki ticaret maliyetlerinin bir göstergesi olarak kullanılmaktadır. Mesafe arttıkça, ulaşım ve diğer lojistik maliyetler de artmakta, bu da ticaret hacmini olumsuz etkilemektedir. Linnemann (1966), mesafenin sadece fiziksel uzaklıkla değil, aynı zamanda kültürel ve kurumsal farklılıklarla da ilişkili olduğunu belirtmiş olsa da daha uzak ülkeler arasındaki ticaretin azalmasının temel nedenini, artan taşıma maliyetleri ve ortaya çıkan zaman kaybı ile ilişkilendirmiştir.

Çekim modeli, genellikle aşağıdaki şekilde formüle edilir (Linnemann, 1966):

$$Ticaret_{ij} = \frac{A \times GSYİH_i \times GSYİH_j}{Mesafe_{ij}}$$

Yukarıda $GSYİH_i$ ve $GSYİH_j$ ticaret yapan iki ülkenin milli geliri, $mesafe_{ij}$ ülkeler arası mesafeyi, A ise genel ticaretin seviyesini belirleyen bir çarpandır.

Çekim modelinin ilk hali sadece ekonomik büyüklük ve mesafeyi içerirken, yıllar içinde model çeşitli faktörleri içerecek şekilde genişletilmiştir. Fiziksel sınırların ticaret üzerindeki etkisini anlamak için sınır etkisi modele dâhil edilmiştir. Fiziksel sınırlar ve gümrük prosedürlerindeki farklılıklar ticaret miktarı

üzerinde azaltıcı ve arttırıcı etkiler oluşturabilmektedir (McCallum, 1995). Anderson ve van Wincoop (2003) ticaret maliyetlerini dikkate alarak çekim modelinin mikroekonomik temellerini güçlendirmiştir. Bu genişletme tarifeleri, kotaları ve diğer ticaret engellerini modele dahil etmiştir. Serbest ticaret anlaşmalarının etkilerini incelemek için modele dahil edilen bir diğer değişken serbest ticaret anlaşmalarıdır. Çünkü ülkeler arasındaki ikili anlaşmalar ticaret bariyerlerini azaltarak iki ülke arasındaki ticareti artırabilmektedir (Baier ve Bergstrand, 2007). Melitz (2008)'e göre ülkeler arasında ortak dil veya kültürel bağların varlığı, iletişim maliyetlerini düşürmekte ve ticari işlemleri kolaylaştırmaktadır. Bu nedenle ortak dil veya kültürel bağlar ticaret hacmini artırabilen faktörler olarak modele eklenmiştir. Son olarak, ülkelerin pazar potansiyeli ve ekonomik yapılarının benzerliği ticaret akımlarını etkileyen önemli faktörler olarak modele ilave edilmiştir. Ülkelerin benzer ekonomik yapıları, üretim ve tüketim kalıplarına sahip olmaları ülkeler arasındaki ikili ticareti teşvik edebilmektedir (Helpman vd., 2008). İkili ticaret ilişkisi incelenecek ülkelerin benzerlik veya farklılıklarına göre bu faktörler daha da genişletilebilmektedir.

Yukarıda belirtilen yapısı itibariyle çekim modeli, uluslararası ticaretin dinamiklerini anlamak için güçlü bir çerçeve sunmaktadır. Ekonomik büyüklük ve mesafe gibi temel değişkenler, ticaret akımlarını büyük ölçüde açıklamakta olup, modelin sadeliği ve uygulanabilirliği, onu ticaret teorisi ve politikası alanında vazgeçilmez bir araç haline getirmiştir. Modelin çeşitli genişletmeleri, ticaretin daha karmaşık ve çok boyutlu doğasının anlaşılmasına da olanak sağlamıştır.

II. LİTERATÜRDEKİ ÖRNEK ÇALIŞMALAR

Çekim modeli kapsamında geleceğe yönelik tahmin konusunda yapılmış birçok çalışma bulunmaktadır. Yapılan çalışmalar hem geleneksel yöntemleri hem de gelişmiş yöntemleri içermektedir. Bu çalışmada makine öğrenimi yöntemlerinin uygulanacağı göz önüne alınarak, benzer yöntemleri uygulayan veya gelişmiş yöntemler ile geleneksel yöntemlerin karşılaştırıldığı çalışmalar incelenmiş ve Tablo 1'de gösterilmiştir.

Tablo 1. Literatürdeki Çalışmalar

Yazar	Amaç	Veri	Kullanılan Yöntemler	En Başarılı Yöntem
Nuroğlu (2012)	15 AB Üyesi İçin İkili Ticaret Tahmini	15 AB üyesi ülkenin 1964-2003 yılları arasındaki verileri	Panel Veri, Sınır Ağı	Sınır Ağı
Circlaey vd. (2017)	Geleceğe Yönelik İkili Ticaret Tahmini	1800'lerden 2014'e kadar olan 200'den fazla farklı ülke ve bölge için 1,9 milyon veri	Lineer Regresyon, Log-Linear Regresyon, KRR, Tam Bağlantılı Sınır Ağları, AR ile Lineer Regresyon, Gecikmeli Çıktı Değerleri Kullanarak Tam Bağlantılı Sınır Ağları	Gecikmeli Çıktı Değerleri Kullanarak Tam Bağlantılı Sınır Ağları
Quimba ve Barral (2018)	APEC Ülkelerinin İkili Ticaret Tahmini	21 APEC ülkesinin 1996-2001 yılları arasındaki 8329 veri	OLS, PPML, GPML, Sınır Ağı	Sınır Ağı
Wohl ve Kennedy (2018)	Geleceğe Yönelik İkili Ticaret Tahmini	1986-2006 yılları arası 68 ülkenin verisi	OLS, PPML, Sınır Ağı	Çok Katmanlı Algılayıcı

Nyoni (2019)	Zimbabve'nin İhracat ve İthalat Tahmini	1975-2017 yılları arası Zimbabve verileri	Sinir Ağı	Hiperbolik Tanjant Fonksiyonlu Sinir Ağı
Batarseh vd. (2019)	Küresel Dana Eti Ticaret Akışı Tahmini	Avustralya, Almanya, Hollanda, Fransa ve ABD'nin 1989-2018 yılları arasındaki verileri	ARIMA, GBoost, XGBoost, LightGBM	LightGBM
Kottou vd. (2020)	Geleceğe Yönelik İkili Ticaret Tahmini	1827 ile 2014 Yılları Arası Ticaret Verileri için 2,7 milyon veri	GSR, Karar Ağacı, LSTM, CNN	Karar Ağacı
Jošić ve Žmuk (2022)	Hırvatistan'ın İkili Dış Ticaret Tahmini	Hırvatistan'ın diğer ülkelerle 2001-2019 yılları arasındaki verileri	Lineer Regresyon, GSR, Çok Katmanlı Algılayıcı	Çok Katmanlı Algılayıcı
Rao vd. (2023)	Geleceğe Yönelik İkili Ticaret Tahmini	1827 ile 2014 Yılları Arası Ticaret Verileri için 1,9 milyon veri	Lineer Regresyon, ARIMA, ARIMAX, Log Dönüşümlü Lineer Regresyon, SVR, Yapay Sinir Ağları, LightGBM	LightGBM

Çekim modeli kapsamında ikili ticaret tahmini konusunda yöntem kıyaslaması yapılan birçok çalışma mevcuttur. Tablodaki çalışmalar genel itibariyle güncel ve yakın geçmişte yapılan uygulamaları içermektedir. Literatürde farklı ülke veya ülke gruplarının ticari ilişkilerinin tahminine ek olarak belirli bir mal grubunun ticaretinin tahmin edilmesine yönelik uygulamalar da yapılmıştır. Tablo 1'deki çalışmalardan Nuroğlu (2012) dikkate alındığında gelişmiş makine öğrenimi uygulamalarının geleneksel yöntemlere göre daha başarılı sonuçlar üretebilme kapasitesine sahip olduğu görülmüştür. Makine öğrenimi yapılarının kıyaslandığı çalışmalarda ise yöntemlerin birbirleri arasındaki algoritma farklılıkları nedeniyle birbirinden farklı sonuçlar ürettiği gözlemlenmiştir. Buna ek olarak ekonominin dinamik yapısı gereği veride ortaya çıkan farklılıklar ve veriler arasındaki örtüntü yapılarındaki değişkenlikler de uygulama aşamasında modellerin ürettiği sonuçları etkilemektedir.

III. TÜRKİYE'NİN TİCARET YAPISI VE TÜRK CUMHURİYETLERİ İLE İLİŞKİSİ


A. Araştırmanın Konusu

Türkiye, coğrafi konumu, ekonomik potansiyeli ve büyüme dinamikleriyle uluslararası ticarete önemli bir konuma sahiptir. Hem Avrupa hem de Asya pazarlarına yakınlığı sayesinde Türkiye, stratejik bir ticaret merkezi hâline gelmiştir. Ülkenin ihracat ve ithalat yapısı sanayi, tarım, hizmetler ve teknoloji gibi çeşitli sektörlerle dayanmaktadır. İhracatında otomotiv, tekstil, makine, gıda ürünleri ve elektronik gibi sektörler öne çıkarken; ithalatında enerji, ham madde, ara mallar ve ileri teknoloji ürünleri dikkat çekmektedir. Türkiye'nin dış ticaret politikaları, küresel ekonomik entegrasyonu ve ticaret hacminin artırılmasına yönelik stratejilerle şekillenmektedir.

Türkiye'nin dünya ticaretindeki konumu, bölgesel iş birlikleri ve serbest ticaret anlaşmaları ile de pekişmektedir. AB, Orta Doğu, Kuzey Afrika ve Asya ülkeleri ile olan ticari ilişkileri, ekonomisinin büyümesine önemli katkılar

sağlamaktadır. Bu kapsamda önce Türkiye'nin ihracat ve ithalat miktarlarının yıllar içerisindeki değişimi incelenecek (Şekil 1) ardından da Türk Cumhuriyetleri ile ihracat (Şekil 3) ve ithalat (Şekil 4) incelenecektir.


Şekil 1. Türkiye'nin İhracat ve İthalat Miktarları (1992-2023) (Milyar Dolar)



Kaynak: UN Comtrade (2024)

Türkiye'nin temel ticaret göstergeleri 1992-2023 yılları arasında önemli bir artış ve çeşitlenme göstermiştir. 1992 yılında 14 milyar dolar seviyesinde olan ihracat, 2023 yılında 250 milyar doları aşmıştır. Aynı dönemde ithalat ise 22 milyar dolardan yaklaşık 360 milyar dolara yükselmiştir. 2001 ekonomik krizi sırasında ithalat geçici olarak azalmıştır. Kriz sonrasında uygulanan yapısal reformlar sonraki dönemde hem ihracatın hem de ithalatın büyümesine önemli katkılar sağlamış ve bu büyüme 2008'e kadar devam etmiştir. 2008 küresel finans krizinin etkisiyle 2009 yılında hem ihracat hem de ithalatta belirgin bir düşüş yaşanmış, ancak takip eden yıllarda hızlı bir toparlanma sürecine girilmiştir. İhracat 2009-2019 arasındaki 10 yıllık dönemde 2015 ve 2016 yılları dışında sürekli artış göstermiştir. Ancak ithalat hem kurdaki yüksek volatilité ve artıştan hem de dünyada enerji fiyatlarındaki düşüşten dolayı 2014-2019 yıllarında düşüş eğilimi göstermiştir. 2020 yılında COVID-19 pandemisinin başlangıcı küresel ticaretin duraksamasına yol açmış ve bu durumdan Türkiye'nin dış ticareti de etkilenmiştir. Bu dönemde ihracat artarken ithalat duraksamıştır. Ancak Türkiye'nin dış ticaret göstergeleri 2021 sonrasında hızlı bir toparlanma eğilimine girmiş ve büyük bir sıçrama göstermiştir.


Şekil 2. Türkiye ile Türk Cumhuriyetleri Arasındaki Uzaklık



Kaynak: Aktaş, Hayati-İpek, Cemil Doğan, (2014), “Frankofoni (Fransızca Konuşan Ülkeler Topluluğu) Türk Dünyası İçin Bir Model Olabilir mi?”, Türk Diasporası ve Türk Dünyası Vizyon 2023, Editör: Almagül İsina, Tasam Yayınları, İstanbul, ss. 45-48.

Çekim modelinin çıkış noktası ülkeler arası mesafenin dış ticaret üzerine etkisi olduğu dikkate alınır; ticaret ilişkisi içerisindeki ülkeler arasındaki mesafelerin önemli olduğu açıktır. Şekil 2’de bu çalışmada değerlendirilecek ülkelerin başkentleri arasındaki mesafeler harita üzerinde gösterilmiştir. Buna göre Türkiye’nin Azerbaycan ile arasındaki mesafe 1767 kilometre, Türkmenistan ile 2543 kilometre, Özbekistan ile 3350 kilometre, Kırgızistan ile 3744 kilometre ve Kazakistan ile 3918 kilometredir.


Şekil 3. Türkiye’nin Türk Cumhuriyetleri’ne Gerçekleştirdiği İhracat Değeri (1992-2023)



Kaynak: UN Comtrade (2024)

Türkiye'nin Türk Cumhuriyetleri'ne yaptığı ihracat da 1992-2023 yılları arasında belirgin bir artış ve çeşitlenme göstermiştir. 1992 yılında bağımsızlıklarını kazanan Türk Cumhuriyetleri (Azerbaycan, Kazakistan, Kırgızistan, Özbekistan, Türkmenistan) ile ticaret, Türkiye'nin dış ticaret stratejisinin önemli bir parçası haline gelmiştir. İhracat miktarları göz önüne alındığında bu ülkeler arasında Türkiye ile en güçlü ortaklık Azerbaycan ile gerçekleşirken, en zayıf ortaklığın Türkmenistan ile gerçekleştiği söylenebilir. İhracat değerlerinin 2008 yılına kadar artış eğiliminde olduğu görülmektedir. 2008 küresel finans krizi, genel olarak Türkiye'nin ihracatını olumsuz etkilerken, Türk cumhuriyetlerine yönelik ihracatta da geçici bir düşüş yaşanmıştır. Kriz sonrasında bu ülkelerle ekonomik ve ticari ilişkilerin güçlendirilmesiyle birlikte ihracat yeniden artış trendine girmiştir. Ancak 2014 yılında Rusya'nın Kırım'ı ilhakıyla uygulanan yaptırımlar ve bölge ülkelerinin Rusya ile ilişkileri (International Monetary Fund (IMF), 2015), bu yaptırımlara bağlı olarak düşen petrol fiyatları (International Energy Agency (IEA), 2015), bu ülkelerde gerçekleşen devalüasyon (World Bank, 2015), Orta Asya'da özellikle Kırgızistan ve Özbekistan ekonomisini etkileyen istikrarsız süreçler (International Crisis Group (ICG), 2015) ve dünya genelinde ekonomik büyümenin yavaşlaması ve Çin gibi üretici bir ekonomideki yavaşlamanın ticareti de yavaşlatması (World Trade Organization (WTO), 2015) sonucu 2015 ve sonrasında bu ülkelere yapılan ihracat miktarı oldukça azalmıştır. 2020 yılında COVID-19 pandemisinin küresel ticareti duraksatmasına rağmen, Türkiye'nin Türk cumhuriyetlerine yönelik ihracatında 2021 ve 2022 yıllarında hızlı bir toparlanma gözlemlenmiştir.

Şekil 4. Türkiye'nin Türk Cumhuriyetleri'nden Gerçekleştirdiği İthalat Değeri (1992-2023)



Kaynak: UN Comtrade (2024)

Türkiye'nin Türk Cumhuriyetlerinden yaptığı ithalat da aynı dönemde kayda değer bir artış sergilemiştir. 1990'ların başında bu ülkelere yapılan ithalat, enerji ve hammadde ağırlıklı olarak başlamış, zamanla çeşitlenmiştir. İhracatta olduğu gibi ithalatta da Türkiye için en güçlü ticaret ortağı Azerbaycan iken, en zayıf ortak Türkmenistan'dır. İthalat değerleri, 2009 yılına kadar ihracat

değerlerine benzer şekilde artarken kriz sonrası süreçte yukarıda ifade edilen ihracatı etkileyen faktörlerin ithalatı da etkilemesi sonucu ithalatta düşüşler ihracata nazaran daha ılımlı olmuştur. Bu durumun politik nedenlerden daha çok petrol fiyatlarındaki düşüş nedeniyle olduğu söylenebilir. 2020 yılında COVID-19 pandemisinin neden olduğu ekonomik durgunluk ithalatı geçici olarak etkilemişse de sonraki yıllarda ekonomik toparlanma ile birlikte ithalat hacmi yeniden artış göstermiştir.

IV. EKONOMETRİK METODOLOJİ

Çalışma 1992'den 2023'e kadar Türkiye'nin Türk Cumhuriyetleri ile yaptığı ikili ticareti (ihracat ve ithalat) gözlemlemekte ve 2024, 2025 yılları için tahminler sunmaktadır. Modeldeki bağımsız değişkenler, ihracatçı ve ithalatçı ülkelerin GSYİH'leri, ülkeler arasındaki mesafe ve kukla değişkenlerdir (dil, sınır, karayla çevrili olma ve DTÖ üyeliği). Yukarıda belirtilen değişkenler, uluslararası ticaretin çekim modeli için ana açıklayıcı değişkenlerdir. Bu nedenle, ticaretin çekim modellerinin tahmin edilmesinde sıklıkla kullanılmaktadırlar. Bu çalışmada da bu değişkenler makine öğrenme algoritmaları için bağımsız değişkenler olarak kullanılmıştır. Bağımlı değişkenler ise bu ülkelere Türkiye'nin yaptığı ihracat ve aynı ülkelere Türkiye'ye yapılan ithalat değerleridir. Değişkenlerin tam listesi, kısa açıklamaları ve veri kaynakları Tablo 2'de sunulmuştur.

Tablo 2. Çalışmada Kullanılan Değişkenler

Değişken	Açıklama	Veri Kaynağı
İhracat	İhracat Miktarı (Bin ABD Doları)	UN Comtrade (2024)
İthalat	İthalat Miktarı (Bin ABD Doları)	UN Comtrade (2024)
İhracatçı GSYİH	İhracatçı Ülke GSYİH (ABD Doları)	Dünya Bankası (2024)
İthalatçı GSYİH	İthalatçı Ülke GSYİH (ABD Doları)	Dünya Bankası (2024)
Dil	İhracatçı ve İthalatçı Ülke Aynı Dili Konuşuyor (0=Hayır, 1=Evet)	CEPII (2024)
Sınır	İhracatçı ve İthalatçı Ülke Sınır Komşusu (0=Hayır, 1=Evet)	CEPII (2024)
Uzaklık	İhracatçı ve İthalatçı Ülke Arasındaki Uzaklık (Km)	CEPII (2024)
Karayla Çevrili	İhracatçı/İthalatçı Ülke Karayla Çevrili Ülke (0=Hayır, 1=Evet)	CEPII (2024)
DTÖ Üyeliği	İhracatçı ve İthalatçı Birlikte DTÖ Üyesi (0=Hayır, 1=Evet)	DTÖ (2024)

Analiz için veriler çeşitli kaynaklardan sağlanmıştır: UN Comtrade, Dünya Bankası, CEPII ve DTÖ. Çalışmada hem ihracat hem de ithalat değişkenleri bin ABD Doları cinsinden ifade edilmiştir. İhracatçı GSYİH ve İthalatçı GSYİH değişkenleri ABD Doları olarak analize dâhil edilmiştir. Dil değişkeni, eğer hem ihracatçı hem de ithalatçı ülkeler resmi dilleri olarak aynı dili paylaşıyorlarsa, değeri "1" (bir) olan bir kukla değişken kullanılmaktadır. Sınır değişkeni de eğer ihracatçı ve ithalatçı ülkeler komşu ülkeler ise değeri "1" (bir) olan kukla değişken kullanılmaktadır. Uzaklık, ticaret ortağı ülkelerin başkentleri arasındaki mesafeyi kilometre cinsinden ifade etmektedir. Karayla çevrili, ortak ülkelere birinin açık denize doğrudan erişimi yoksa kukla değişken "1" (bir) olarak alınmaktadır.


İthalatçı ve ihracatçı ülkelerin her ikisi de Dünya Ticaret Örgütü üyesi ise, DTÖ kukla değişkeninin değeri “1” (bir) olarak alınmaktadır.

Türkiye, dünya genelinde 180'den fazla ülke ile ticaret yapıyor olsa da makalede yukarıda da belirtildiği gibi yalnızca Türk Cumhuriyetleri'nden oluşan ticaret ortakları ele alınacaktır. Amaç, ikili uluslararası ticaret akışlarını kapsamlı bir şekilde tahmin edebilecek bir analiz çerçevesi sunmaktır. 2024 ve 2025 yılları için Türkiye'nin ikili ihracat ve ithalatının gelecekteki değerlerini tahmin etmede en başarılı yöntemi tespit etmek amacıyla farklı tahmin teknikleri ve algoritmaları uygulanmıştır. Bu amaçla, Waikato Üniversitesi tarafından geliştirilen ve açık kaynaklı bir makine öğrenimi yazılımı olan WEKA ve seçilen makine öğrenme algoritmaları (Lineer Regresyon, Gauss Süreç Regresyonu ve Çok Katmanlı Algılayıcılar) kullanılmıştır.

A. Lineer Regresyon (Linear Regression)

Lineer regresyon, bağımlı değişken (y) ile bir veya daha fazla bağımsız değişken (x_1, x_2, \dots, x_n) arasındaki ilişkiyi modellemek için kullanılır. Basit lineer regresyon modelde değişkenler arasındaki ilişki iki boyutlu düzlem üzerinde aşağıdaki şekilde gösterilmektedir:

Şekil 5. Lineer Regresyon



Kaynak: Bangdiwala, S. I. (2018). Regression: simple linear. International Journal of Injury Control and Safety Promotion, 25(1), 113–115. <https://doi.org/10.1080/17457300.2018.1426702>.

Yukarıdaki iki boyutlu kartezyen koordinat yapısında y bağımlı (tahmin edilmek istenen) değişkeni, x_1, x_2, \dots, x_n bağımsız (girdi) değişkenleri, β_0 regresyon sabitini, $\beta_1, \beta_2, \dots, \beta_n$ regresyon katsayılarını (eğimlerini), ϵ hata terimini ifade eder. Bu noktadan hareketle, bağımlı değişkeni açıklamak için bağımsız değişken, regresyon sabiti, regresyon katsayıları ve hata terimini içeren aşağıdaki eşitlik yapısı kullanılır:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon$$

Lineer regresyonun amacı, gözlemlenen değer ile modelin tahmin ettiği değerler arasındaki farkı, diğer bir deyişle hata düzeyini (ϵ) minimize etmektir. Bu fark MSE (Ortalama Kare Hatası), RMSE (Kök Ortalama Kare Hata), MAE

(Ortalama Mutlak Hata), MAPE (Ortalama Mutlak Yüzde Hata) gibi farklı yöntemlerle hesaplanabilmektedir.

B. Gauss Süreç Regresyonu (Gaussian Process Regression) (GSR)

GSR, genellikle doğrusal olmayan çok değişkenli regresyon ve sınıflandırma problemlerin çözümü için kullanılan başarılı ve esnek bir makine öğrenme yöntemidir. GSR'nin en önemli avantajı, sonuçları üzerinde belirsizlik ölçümleri yapılabilmesi ve böylece parametrik olmayan küçük veri setlerinde bile başarılı tahminler üretebilmesidir (Korkmaz et al., 2022; Snelson & Ghahramani, 2007). Gauss süreç regresyonunda y 'nin bağımlı değişken, x 'in bağımsız değişken olduğu varsayıldığında fonksiyon aşağıda belirtildiği şekilde oluşmaktadır (Rasmussen & Williams, 2006):

$$y=f(x)+\varepsilon$$

Bu fonksiyon, lineer regresyondaki varsayıma benzerdir. Bir bağımlı değişken, bağımsız değişkenin fonksiyonu ve hata teriminden oluşmaktadır.

Gauss süreci, bir noktada (x) belirli bir Gauss dağılımı içindeki bir değer olduğu varsayılır. Bu, $f(x)$ için bir ortalama ($\mu(x)$) ve bir varyans ($\sigma^2(x)$) sağlar (Rasmussen & Williams, 2006):

$$f(x) \sim N(\mu(x), \sigma^2(x))$$

Çekirdek fonksiyonu olarak da tanımlanan kovaryans fonksiyonu, iki nokta arasındaki ilişkiyi modellemek için kullanılır. Diğer bir deyişle, veri noktalarının birbiriyle nasıl ilişkili olduğunu ifade eder. Kovaryans fonksiyonu aşağıdaki şekilde ifade edilir (Rasmussen, 2004; Rasmussen & Williams, 2006):

$$k(x, x') = \text{cov}(f(x), f(x'))$$


Her bir nokta için, tahmin edilen değer ve tahmin edilen belirsizlik, Gauss dağılımı ile ifade edilir (Rasmussen & Williams, 2006):

$$\mu(x) = k(x, X_{train}) [K_{train} + \sigma_n^2 I]^{-1} y$$

$$\sigma^2(x) = k(x, x) - k(x, X_{train}) [K_{train} + \sigma_n^2 I]^{-1} k(X_{train}, x)$$

Burada X_{train} eğitim veri setini, K_{train} eğitim veri noktalarının kovaryans matrisini ve σ_n^2 gözlem hatalarının varyansını temsil eder.


Şekil 6. Standart Normal Dağılım



Kaynak: Moisl, Hermann. (2009). Sura Length and Lexical Probability Estimation in Cluster Analysis of the Qur'an. ACM Trans. Asian Lang. Inf. Process.. 8. 10.1145/1644879.1644886.

Matematiksel açıklaması yukarıda belirtilen bu model Gauss'un normal dağılım yapısından türetilmiştir. Gözlem değerleri bir frekans yapısı içerisinde Şekil 6'daki gibi histogram grafiğine aktarıldığında, 2σ (standart sapma) içerisinde kalan (%95,45) alan için bir güven aralığı oluşturularak bu tahminin alt ve üst sınırlarını tahmin etmektedir. Dolayısıyla girdi verilerin yoğun ve birbirlerine yaklaştığı bölgelerde tahmindeki güven aralıkları daralırken, girdi verilerin yoğunluğunun azaldığı bölgelerde güven aralıkları genişlemektedir.

Şekil 7. Gauss Süreç Regresyonu




Kaynak: Cheremisin, A., Usov, E., Kolchanov, B., Krylov, A., Valkovich, A., Lykhin, P., Ulyanov, V., Khogoeva, E., & Podnebesnykh, A. (2022). Mathematical justification for optimizing operating conditions of gas and gas condensate producing wells. *Energies*, 15(10), 3676. <https://doi.org/10.3390/en15103676>

Şekil 7'de GSR çalışma prensipleri çerçevesinde bağımlı ve bağımsız değişkenler arasındaki ilişkiye bağlı olarak kırmızı noktalar ile eğitim verilerinin, kesikli siyah çizgi ile hedef fonksiyonun, mavi çizgi ile tahmin fonksiyonunun ve mavi dolgu ile eğitim verilerinin dağılımına bağlı olarak 2σ (standart sapma) sınırları çerçevesinde GSR tahminlerinin güven aralıkları gösterilmiştir. Şekil 7'de de görüleceği gibi girdi veri yoğunluğunun yüksek ve birbirine yakın olduğu noktalarda tahmin aralıkları daralırken, girdi veriler için yoğunluğun ve yakınlığın azaldığı noktalarda tahmin aralıkları da genişlemektedir.

C. Çok Katmanlı Algılayıcılar (Multilayer Perceptron) (ÇKA)

Çok katmanlı algılayıcılar, birden fazla katmandan oluşan yapay sinir ağlarıdır. Temel yapısında model üç farklı katman bulundurulur. Bunlardan ilki veri setindeki özellik sayısına göre nöron sayısının belirlendiği giriş katmanıdır. İkincisi tanımlı sayıda bulunan ve her katman için nöron sayısı ve aktivasyon fonksiyonunun deneme yanılma yöntemi ile belirlendiği gizli katmandır. Üçüncüsü ise probleme bağlı olarak bir veya daha fazla nöronun belirlendiği çıkış katmanıdır.



Kaynak: Ben Ameer, H., Boubaker, S., Ftiti, Z., Louhichi, W., & Tissaoui, K. (2023). Forecasting commodity prices: Empirical evidence using deep learning tools. *Annals of Operations Research*. Advance online publication. <https://doi.org/10.1007/s10479-022-05076-6>

ÇKA'da ilk olarak ileri besleme işlemi uygulanır. Bu aşamada girdi katmanından başlanarak her katmandaki nöronların çıktıları hesaplanır ve çıktı katmanına doğru ilerler. Bir ÇKA'da her katman, bir önceki katmandaki nöronların çıktıları alır ve kendi aktivasyon fonksiyonunu kullanarak yeni bir çıktı üretir. İleri besleme işlemi genellikle şu şekilde ifade edilir (Bishop, 1995):

$$z^l = W^l a^{l-1} + b^l$$

$$a^l = f(z^l)$$

Yukarıdaki formülde l katman indeksini, z^l katmanın ağırlık girişini, W^l katmanın ağırlık matrisini, a^{l-1} önceki katmanın çıktısını, b^l katmanın bias vektörünü, $f(z^l)$ aktivasyon fonksiyonunu ifade etmektedir.


Modelin eğitimi sırasında geribesleme algoritması kullanılarak ağırlık ve bias parametrelerinin güncellenmesi sağlanır. Geribesleme, kayıp fonksiyonunun türevlerini hesaplayarak ağdaki hata miktarını geriye doğru yayarak yapar. Ardından, bu türevler kullanılarak ağ parametreleri (ağırlıklar ve biaslar) gradient iniş veya başka bir optimizasyon algoritması ile güncellenir (Rumelhart et al., 1986):

$$W^l = W^l - \eta \frac{\partial L}{\partial W^l}$$

$$b^l = b^l - \eta \frac{\partial L}{\partial b^l}$$

Yukarıdaki formülde η öğrenme oranını, $\frac{\partial L}{\partial W^l}$ ağırlıkların gradyanını, $\frac{\partial L}{\partial b^l}$ biasların gradyanını ifade etmektedir. Çalışma süreci detaylı şekilde açıklanan ÇKA modeli, geliştirilmiş delta öğrenme kuralı çerçevesinde şekil 9'daki gibi görselleştirilir:

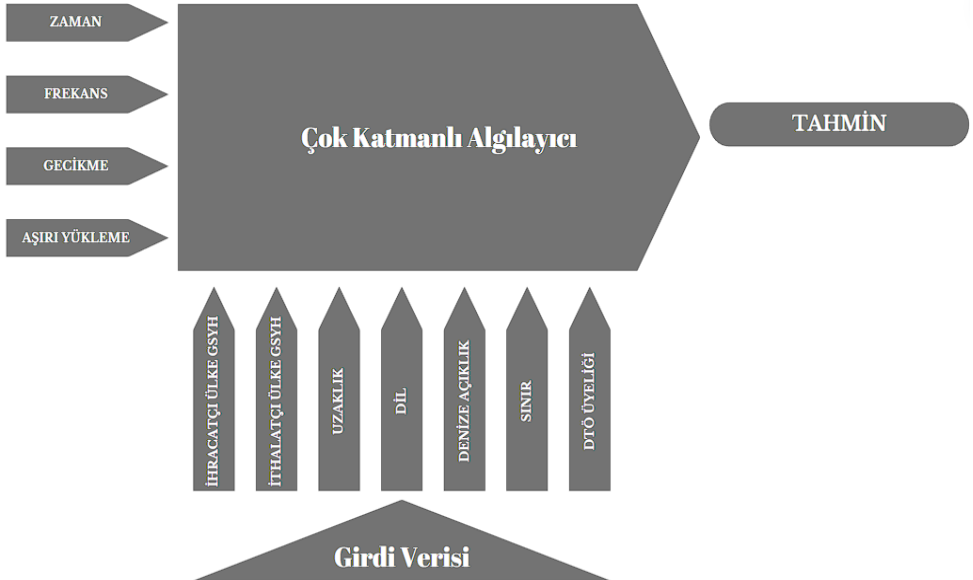
Şekil 9. Çok Katmanlı Algılayıcı Algoritmasının Çalışma Yapısı



Kaynak: Kuşkan E. ve Çodur M. Y. "Trafik kazalarının sınıflandırılmasında çok katmanlı algılayıcı, regresyon ve en yakın komşuluk algoritmalarının performans analizi", Politeknik Dergisi, 25(1): 373-380, (2022).

Bu çalışma kapsamında kullanılacak WEKA uygulamasının çalışma prensibi ile girdi değişkenler çerçevesinde ÇKA ile çıktının nasıl elde edileceği ise Şekil 10'de gösterilmiştir:

Şekil 10. WEKA Uygulamasındaki Çok Katmanlı Algılayıcılar Analiz Yapısı



Kaynak: Jošić, H., & Žmuk, B. (2022). A Machine Learning Approach to Forecast International Trade: The Case of Croatia. Business Systems Research, 13(3), 144-160. <https://doi.org/10.2478/bsrj-2022-0030>

D. Model Çıktılarının Doğrulaması

Çalışma kapsamında kullanılan her tahmin algoritmasının değerlendirilmesi, ortalama mutlak yüzde hata (MAPE) hesaplanarak yapılacaktır. Ortalama mutlak yüzde hatası aşağıdaki formül ile tanımlanır:

Yukarıdaki formülde, n veri noktası sayısını, Y_i gözlemlenen değerleri, \hat{Y}_i ise model tarafından tahmin edilen değerleri ifade etmektedir. MAPE değeri ne kadar düşük olursa, belirli bir tahmin algoritması Türkiye'nin ikili ihracat ve ithalatını tahmin etmede o kadar başarılı olacaktır. MAPE değerleri gözlemlenen hataların aralığına göre yorumlanacaktır. MAPE değerinin ondan düşük olması, yüksek doğrulukta tahmin olarak yorumlanabilir, 10-20 aralığındaki MAPE değeri iyi tahmin olarak yorumlanabilir, 20-50 aralığındaki değer makul tahmin olarak kabul edilirken, 50'den yüksek MAPE değeri ise hatalı tahmin olarak yorumlanabilir (Hyndman & Koehler, 2006; Žmuk & Jošić, 2020). Her tahmin algoritması genel olarak gözlemlenmiş ve karşılaştırılmıştır. Son olarak, ihracat ve ithalatı tahmin etmede hangi tahmin algoritmasının optimal olarak kullanılması gerektiği konusunda bir öneri sunulabilir.

BULGULAR

Tablo 3'te örnek olarak Türkiye'nin Azerbaycan'a yaptığı ihracat tahminlemesi analiz sonucu paylaşılmıştır ve WEKA uygulamasında yapılan analiz sonuçlarına göre oluşan çıktı aşağıdaki şekildedir.

Tablo 3. Türkiye'nin Azerbaycan'a İhracat Tahmini

Yıl	İhracat	İhracatçı GSYİH	İthalatçı GSYİH	Sınır	Dil	Uzaklık	Karayla Çevrililik	DTÖ Üyeliği
1992	102.000	159.000.000	4.900.000	1	0	1767	1	0
1993	68.200	180.000.000	3.900.000	1	0	1767	1	0
1994	132.000	131.000.000	3.300.000	1	0	1767	1	0
1995	161.000	169.000.000	3.000.000	1	0	1767	1	0
1996	239.000	181.000.000	3.200.000	1	0	1767	1	0
1997	320.000	190.000.000	3.900.000	1	0	1767	1	0
1998	325.000	269.000.000	4.400.000	1	0	1767	1	0
1999	248.000	250.000.000	4.600.000	1	0	1767	1	0
2000	230.000	267.000.000	5.300.000	1	0	1767	1	0
2001	225.000	196.000.000	5.700.000	1	0	1767	1	0
2002	231.000	233.000.000	6.200.000	1	0	1767	1	0
2003	315.000	303.000.000	7.300.000	1	0	1767	1	0
2004	404.000	392.000.000	8.700.000	1	0	1767	1	0
2005	528.000	483.000.000	13.200.000	1	0	1767	1	0
2006	695.000	531.000.000	21.000.000	1	0	1767	1	0
2007	1.048.000	647.000.000	33.100.000	1	0	1767	1	0
2008	1.667.000	730.000.000	48.900.000	1	0	1767	1	0
2009	1.400.000	615.000.000	44.300.000	1	0	1767	1	0
2010	1.550.000	731.000.000	52.900.000	1	0	1767	1	0
2011	2.064.000	775.000.000	66.000.000	1	0	1767	1	0
2012	2.585.000	789.000.000	68.700.000	1	0	1767	1	0
2013	3.174.000	822.000.000	73.600.000	1	0	1767	1	0
2014	3.061.000	934.000.000	75.200.000	1	0	1767	1	0
2015	1.898.000	859.000.000	53.100.000	1	0	1767	1	0
2016	1.286.000	858.000.000	37.800.000	1	0	1767	1	0
2017	1.357.000	859.000.000	40.900.000	1	0	1767	1	0

2018	1.474.000	778.000.000	47.100.000	1	0	1767	1	0
2019	1.789.000	761.000.000	48.200.000	1	0	1767	1	0
2020	2.085.000	720.340.000	42.700.000	1	0	1767	1	0
2021	2.343.000	819.870.000	54.600.000	1	0	1767	1	0
2022	2.528.000	907.120.000	78.720.000	1	0	1767	1	0
2023	2.802.000	920.270.000	79.660.000	1	0	1767	1	0
2024*	3.229.000	1.035.710.000	86.070.000	1	0	1767	1	0
2025*	3.140.000	1.125.120.000	99.185.000	1	0	1767	1	0

Türkiye'nin Türk Cumhuriyetleri ile ikili ticaretindeki ihracat ve ithalat miktarları üzerinden üç yöntem için de yapılan analizlerin sonucunda ortaya çıkan MAPE değerleri yeşil rengin başarılı, kırmızı rengin başarısız tahminleri ifade etmek amacıyla kullanıldığı renk ölçekleri ile tablo 4 ve tablo 5'teki şekilde gösterilmiştir. Modeller, tahmin edilmek istenen iki yıl için de ortaya çıkan MAPE değerlerinin ortalaması alınarak değerlendirilecektir.

Tablo 4. İhracat Tahmininde Model ve Yıllara Göre MAPE(Hata) Değerleri

Türkiye İhracatı	Azerbaycan			Kazakistan			Kırgızistan			Özbekistan			Türkmenistan		
	ÇKA	GSR	LR	ÇKA	GSR	LR	ÇKA	GSR	LR	ÇKA	GSR	LR	ÇKA	GSR	LR
2024*	8,78	22,8	22,86	9,24	23,49	22,74	25,89	89,6	20,86	15,45	26,04	18,98	13,57	30,47	33,55
2025*	11,84	100,5	27,15	17,91	83,18	42,67	21,99	160,8	29,48	16,39	95,55	20,87	15,59	146,5	30,97

İhracat için yapılan analiz sonuçlarına göre ÇKA (çok katmanlı algılayıcılar) Türkiye'nin analize konu ülkelere iki yıllık ihracatını tahmin etmede en başarılı yöntem olmuştur. ÇKA'nın ardından en başarılı tahmin üreten ikinci yöntem LR (lineer regresyon) olurken en başarısız yöntem ise GSR (gauss süreç regresyonu) olmuştur. Daha önce yöntemler açıklanırken belirtildiği gibi ÇKA yapısı gereği değişken ağırlıklarını optimize ederek tahminler üretmektedir. Bu durum analiz sonuçlarında da görüldüğü gibi tahmin başarısını yükseltmektedir. LR yöntemi geçmiş dönemdeki trend üzerinden hata düzeyini minimize ederek tahmin yapmaktadır. Geçmiş verilerin uzun süreli yükselen trend yapısı LR yönteminin tahmin başarısında etkili olmuştur. GSR ise yine yöntem açıklanırken belirtildiği gibi veri yoğunluğu ve volatilitenin düşük olduğu noktalarda iyi tahminler ortaya çıkartmaktadır. Özellikle tahmin edilen ikinci yıl için artan standart sapma nedeniyle oluşan yüksek MAPE değerleri de bu durumu kanıtlamaktadır.

Tablo 5. İthalat Tahmininde Model ve Yıllara Göre MAPE(Hata) Değerleri

Türkiye İthalatı	Azerbaycan			Kazakistan			Kırgızistan			Özbekistan			Türkmenistan		
	ÇKA	GSR	LR	ÇKA	GSR	LR	ÇKA	GSR	LR	ÇKA	GSR	LR	ÇKA	GSR	LR
2024*	21,53	27,66	43,71	15,88	31,98	46,73	35,25	53,17	44,12	39,35	38,61	47,06	15,97	27,81	31,67
2025*	22,19	73,83	41,58	15,19	96,67	57,21	31,75	181,1	45,27	40,67	166,3	37,11	17,55	84,16	41,32

İthalat tahminlemesi için yapılan analiz sonuçlarına göre ÇKA (çok katmanlı algılayıcılar) Türkiye'nin analize konu ülkelere iki yıllık ithalatını tahmin etmede en başarılı yöntem olmuştur. İthalat için yapılan tahminlerde de ihracattakine benzer şekilde ÇKA'nın ardından en başarılı tahmin üreten ikinci yöntem LR (lineer regresyon) olurken en başarısız yöntem ise GSR (gauss süreç regresyonu) olmuştur. İhracat sonuçlarından farklı olarak ilk yıl için yapılan tahminlerde GSR'nin MAPE değerleri Kırgızistan dışındaki ülkeler için LR'den daha başarılı sonuçlar üretmiştir. Ancak ikinci yıl için yapılan tahminlerde yine diğer yöntemlere göre aşırı yüksek MAPE değerleri ile başarısız tahminler ürettiği görülmüştür.

SONUÇ

Bu çalışma, Türkiye'nin Türk Cumhuriyetleri (Azerbaycan, Kazakistan, Kırgızistan, Özbekistan ve Türkmenistan) ile olan ticaret miktarını uluslararası ticaret çekim modeli kapsamında analiz ederek, önümüzdeki iki yıllık süreç için ticaret hacminin tahmin edilmesini amaçlamıştır. 1992-2023 yılları arasındaki ihracat ve ithalat verileri, ülkelerin milli gelirleri ve aralarındaki mesafe gibi sayısal değişkenlerin yanı sıra sınır, dil, karayla çevrili durum ve Dünya Ticaret Örgütü (DTÖ) üyelikleri gibi kukla değişkenler kullanılarak incelenmiştir. Bu veriler, Lineer Regresyon, Gauss Süreç Regresyonu ve Çok Katmanlı Algılayıcılar gibi çeşitli makine öğrenmesi modelleriyle işlenmiştir.

Çalışmanın sonuçları, farklı modellerin performansını değerlendirmek için kullanılan Ortalama Mutlak Yüzde Hata (MAPE) değerleri ile belirlenmiştir. Analizlerde, ÇKA modelinin diğer modellere kıyasla daha düşük MAPE değerlerine sahip olduğu ve daha küçük hata miktarları ile tahmin sağladığı tespit edilmiştir. Bu durum, çok katmanlı algılayıcıların, ticaret verilerindeki karmaşık desenleri ve ilişkileri daha iyi yakalayabildiğini ve bu nedenle gelecekteki ticaret eğilimlerini öngörmeye daha etkili olduğunu göstermektedir.

Çalışmanın bulguları, Türkiye ve Türk Cumhuriyetleri arasındaki ticaret ilişkilerinin daha iyi anlaşılmasına ve bu ilişkilerin gelecekteki seyrinin tahmin edilmesine önemli katkılar sağlamaktadır. Özellikle, ileri düzey makine öğrenmesi yöntemlerinin ticaret dinamiklerini anlamada ve ticaret politikalarını şekillendirmede ne kadar etkili olabileceğini vurgulamaktadır. Bu bağlamda, çok katmanlı algılayıcıların sunduğu yüksek doğruluk oranları, bölgesel ekonomik politikaların oluşturulması ve ticaret stratejilerinin geliştirilmesi açısından değerli içgörüler sunmaktadır.

Sonuç olarak, bu çalışma, Türkiye'nin Türk Cumhuriyetleri ile olan ticaretinin gelecekteki eğilimlerini öngörmeye çok katmanlı algılayıcılar gibi ileri düzey makine öğrenmesi modellerinin kullanımının ne kadar yararlı olabileceğini ortaya koymaktadır. Bu tür modellerin, sadece mevcut ticaret akışlarının analizinde değil, aynı zamanda gelecekteki ticaret potansiyelinin tahmin edilmesinde de kullanılabilirliği, politika yapıcılar ve ekonomi planlamacıları için önemli avantajlar sunmaktadır. Çalışmanın bulguları, bölgesel ticaretin daha etkin yönetilmesi ve geliştirilmesi için gerekli stratejik kararların alınmasında rehberlik edecektir.

Araştırma ve Yayın Etiği Beyanı

Makalenin tüm süreçlerinde Yönetim ve Ekonomi Dergisi'nin araştırma ve yayın etiği ilkelerine uygun olarak hareket edilmiştir.

Yazarların Makaleye Katkı Oranları

Yazarlar çalışmaya eşit oranda katkı sağlamıştır.

Çıkar Beyanı

Yazarın herhangi bir kişi ya da kuruluş ile çıkar çatışması yoktur.

KAYNAKÇA

- Aktaş, Hayati-İpek, Cemil Doğan, (2014), “Frankofoni (Fransızca Konuşan Ülkeler Topluluğu) Türk Dünyası İçin Bir Model Olabilir mi?”, Türk Diasporası ve Türk Dünyası Vizyon 2023, Editör: Almagül İşina, Tasam Yayınları, İstanbul, ss. 45-48. https://tasam.org/tr-TR/Icerik/53597/frankofoni_fransizca_konusan_ulkeler_toplulugu_turk_dunyasi_icin_bir_model_olabilir_mi
- Alpaydin, E. (2014). Introduction to Machine Learning, third edition. MIT Press. <https://books.google.com.tr/books?id=7f5bBAAAQBAJ>
- Anderson, J. E., & van Wincoop, E. (2003). Gravity with Gravititas: A Solution to the Border Puzzle American Economic Review, 93(1), 170–192. <https://doi.org/10.1257/000282803321455214>
- Baier, S. L., & Bergstrand, J. H. (2007). Do free trade agreements actually increase members' international trade? Journal of International Economics, 71(1), 72–95. <https://doi.org/https://doi.org/10.1016/j.jinteco.2006.02.005>
- Bangdiwala, S. I. (2018). Regression: simple linear. International Journal of Injury Control and Safety Promotion, 25(1), 113–115. <https://doi.org/10.1080/17457300.2018.1426702>
- Batarseh, F., Gopinath, M., Nalluru, G., & Beckman, J. (2019). Application of machine learning in forecasting international trade trends. ArXiv Preprint ArXiv:1910.03112.
- Ben Ameer, H., Boubaker, S., Ftiti, Z., Louhichi, W., & Tissaoui, K. (2023). Forecasting commodity prices: Empirical evidence using deep learning tools. Annals of Operations Research. Advance online publication. <https://doi.org/10.1007/s10479-022-05076-6>
- Bergstrand, J. (1985). The Gravity Equation In International Trade: Some Microeconomic Foundations And Empirical Evidence. The Review of Economics and Statistics, 67, 474–481. <https://doi.org/10.2307/1925976>
- Bishop, C. M. (1995). Neural Networks for Pattern Recognition. Clarendon Press. <https://books.google.com.tr/books?id=TOS0BgAAQBAJ>
- Cheremisin, A., Usov, E., Kolchanov, B., Krylov, A., Valkovich, A., Lykhin, P., Ulyanov, V., Khogoeva, E., & Podnebesnykh, A. (2022). Mathematical justification for optimizing operating conditions of gas and gas condensate producing wells. Energies, 15(10), 3676. <https://doi.org/10.3390/en15103676>
- Circlaey, S., Kanitkar, C., & Kumazawa, D. (2017). Bilateral trade flow prediction. Unpublished Manuscript, Available for Download at <Http://Cs229.Stanford.Edu/Proj2017/Final-Reports/5240224.Pdf>.
- Goldfarb, A., & Treffer, D. (2018). Artificial Intelligence, and International Trade. The Economics of Artificial Intelligence: An Agenda, 463–492.
- Helpman, E., Melitz, M., & Rubinstein, Y. (2008). Estimating Trade Flows: Trading Partners and Trading Volumes. The Quarterly Journal of Economics, 123(2), 441–487. <https://econpapers.repec.org/RePEc:oup:qjecon:v:123:y:2008:i:2:p:441-487>.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. International Journal of Forecasting, 22(4), 679–688. <https://doi.org/https://doi.org/10.1016/j.ijforecast.2006.03.001>
- International Crisis Group (ICG). (2015). Central Asia Reports.
- International Energy Agency (IEA). (2015). World Energy Outlook.

- International Monetary Fund (IMF). (2015). *Regional Economic Outlook: Middle East and Central Asia*.
- Jošić, H., & Žmuk, B. (2022). A Machine Learning Approach to Forecast International Trade: The Case of Croatia. *Business Systems Research*, 13(3), 144–160. <https://doi.org/10.2478/bsrj-2022-0030>
- Korkmaz, M., Dogan, A., & Kirmaci, V. (2022). Performance Analysis of Counterflow Ranque – Hilsch Vortex Tube with Linear Regression, Support Vector Machines and Gaussian Process Regression Method. 361–370. <https://doi.org/10.30855/gmbd.0705015>
- Kottou, E. M., Grubelich, T. A., & Wang, X. (2020). Bilateral Trade Flow Prediction Models Enhanced By Wavelet and Machine Learning Algorithms. 2020 International Conference on Computational Science and Computational Intelligence (CSCI), 1510–1516. <https://doi.org/10.1109/CSCI51800.2020.00279>
- Kulkarni, A., & More, A. (2016). Formulation of a Prediction Index with the Help of WEKA Tool for Guiding the Stock Market Investors. *Oriental Journal of Computer Science and Technology*, 9, 212–225. <https://doi.org/10.13005/ojst/09.03.07>
- Kuşkapan E. ve Çodur M. Y. “Trafik kazalarının sınıflandırılmasında çok katmanlı algılayıcı, regresyon ve en yakın komşuluk algoritmalarının performans analizi”, *Politeknik Dergisi*, 25(1): 373-380, (2022).
- Linnemann, H. (1966). An econometric study of international trade flows [North-Holland Pub. Co.]. <https://doi.org/LK> - <https://worldcat.org/title/239355>
- Melitz, J. (2008). Language and foreign trade. *European Economic Review*, 52(4), 667–699. <https://doi.org/https://doi.org/10.1016/j.euroecorev.2007.05.002>
- Moisl, Hermann. (2009). Sura Length and Lexical Probability Estimation in Cluster Analysis of the Qur’an. *ACM Trans. Asian Lang. Inf. Process.*. 8. 10.1145/1644879.1644886.
- Nuroğlu, E. (2012). Estimating Trade Flows of Turkey Using Panel Data Analysis and Neural Networks. *Bartın Üniversitesi İİBF Dergisi*, 3, 13–34.
- Nyoni, T. (2019). Exports and imports in Zimbabwe: recent insights from artificial neural networks.
- Pöyhönen, P. (1963). A Tentative Model for the Volume of Trade between Countries. *Weltwirtschaftliches Archiv*, 90, 93–100. <http://www.jstor.org/stable/40436776>
- Quimba, F. M. A., & Barral, M. A. A. (2018). Exploring neural network models in understanding bilateral trade in APEC: A review of history and concepts (Issues 2018–33). *Philippine Institute for Development Studies (PIDS)*. <https://hdl.handle.net/10419/211053>
- Rao, P., Baheti, P., & Ramesh, R. (2023). TRADE FLOW ESTIMATION BETWEEN GLOBAL ECONOMIES. *International Journal of Advance Computational Engineering and Networking (IJACEN)*, 11(4), 1–5.
- Rasmussen, C. E. (2004). Gaussian Processes in Machine Learning. In O. Bousquet, U. von Luxburg, & G. Rätsch (Eds.), *Advanced Lectures on Machine Learning: ML Summer Schools 2003, Canberra, Australia, February 2 - 14, 2003, Tübingen, Germany, August 4 - 16, 2003, Revised Lectures* (pp. 63–71). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-28650-9_4
- Rasmussen, C. E., & Williams, C. K. I. (2006). *Gaussian processes for machine learning*. MIT Press.
- Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533–536. <https://doi.org/10.1038/323533a0>
- Snelson, E., & Ghahramani, Z. (2007). Local and global sparse Gaussian process approximations. *Journal of Machine Learning Research*, 2, 524–531.
- Tinbergen, J. (1962). *Shaping the World Economy; Suggestions for an International Economic Policy*. <http://hdl.handle.net/1765/16826>
- UN Comtrade. (2024). <https://comtradeplus.un.org/TradeFlow>
- Wohl, I., & Kennedy, J. (2018). *Neural network analysis of international trade*. US International Trade Commission: Washington, DC, USA.
- World Bank. (2015). *Kazakhstan Economic Update*.
- World Trade Organization (WTO). (2015). *World Trade Report*.

Žmuk, B., & Jošić, H. (2020). Forecasting Stock Market Indices Using Machine Learning Algorithms. *Interdisciplinary Description of Complex Systems*, 18(4), 471–489. <https://doi.org/10.7906/indecs.18.4.7>

SUMMARY

This study aims to analyze Turkey's trade volume with the Turkic Republics (Azerbaijan, Kazakhstan, Kyrgyzstan, Uzbekistan, and Turkmenistan) within the framework of the international trade gravity model and to forecast the trade volume with these countries for the years 2024 and 2025. The analysis utilizes export and import data between Turkey and these countries from 1992 to 2023. The data includes countries' GDPs and distances as numerical variables, while border, language, landlocked status, and World Trade Organization (WTO) memberships are used as dummy variables.

The data has been processed using various machine learning models to predict trade volumes, including Linear Regression, Gaussian Process Regression and Multilayer Perceptron (MLPs). The success of these models has been compared based on Mean Absolute Percentage Error (MAPE) values. The analysis results indicate that the MLP model provides the most accurate predictions with the lowest MAPE values.

The international trade gravity model is widely used to understand the fundamental factors determining trade flows. This model analyzes the impact of economic size and distance between countries on trade volumes. In addition to these core variables, this study also evaluates factors such as shared borders, common language, landlocked status, and WTO membership. Shared borders and common language typically facilitate trade, while landlocked status can increase trade costs. WTO membership is significant for trade liberalization and reducing trade barriers.

The analysis of the data offers an in-depth perspective on the complex dynamics of trade relations between Turkey and the Turkic Republics. The data from 1992 to 2023 enables an examination of the evolution of these relationships over time and the impact of economic and political changes on trade volumes. In this context, the effects of economic size, geographical, and political factors on trade flows have been thoroughly analyzed.

The use of machine learning models provides significant advantages in predicting trade volumes. Linear Regression models the linear relationships between variables, while Gaussian Process Regression can capture more flexible and complex relationships. Multilayer Perceptron, employing deep learning techniques, can recognize intricate patterns in trade data. Comparing these models is crucial for identifying the most suitable forecasting method.

The study's findings show that the Multilayer Perceptron model is the most successful in predicting trade volumes. The model's low MAPE values demonstrate its superiority in understanding complex trade dynamics and forecasting future trade trends. This finding underscores the effectiveness of advanced machine learning methods in trade analysis.

A better understanding and prediction of trade relations between Turkey and the Turkic Republics will significantly contribute to the formulation of regional economic policies. Accurate trade volume forecasts play a critical role in economic planning and policy-making processes. Additionally, this study provides valuable insights for developing strategies to enhance trade with these countries.

Specifically, the application of such analyses in shaping and implementing trade policies can provide a solid foundation for increasing economic cooperation and reducing trade barriers. In this context, the study's findings can help Turkey manage its regional trade policies more effectively and strengthen its economic relationships with the Turkic Republics.

Moreover, this study highlights the potential of machine learning models in trade analysis. The ability to process large datasets and uncover complex relationships allows for more accurate and insightful predictions. These capabilities are particularly valuable in the rapidly changing global economic environment, where traditional models may fall short in capturing emerging trends and patterns.

The implications of this study extend beyond the academic sphere. Policymakers can leverage the insights derived from advanced machine learning models to devise more informed and strategic economic policies. For instance, understanding the trade dynamics between Turkey and the Turkic Republics can help identify key areas for policy intervention, such as infrastructure development, trade agreements, and diplomatic initiatives.

Furthermore, this research underscores the importance of integrating modern analytical tools in economic research. The successful application of machine learning models in this study sets a precedent for future research endeavors, encouraging the adoption of similar methodologies in other contexts. This approach not only enhances the accuracy of predictions but also broadens the scope of analysis, allowing researchers to explore a wider range of variables and their interactions.

In conclusion, this study provides a comprehensive analysis of trade relations between Turkey and the Turkic Republics and forecasts future trade volumes using advanced machine learning models. The results demonstrate the effectiveness of Multilayer Perceptron in predicting trade volumes, highlighting the potential of sophisticated machine learning techniques in understanding complex trade dynamics. This research offers valuable insights for policymakers and contributes to the academic literature on international trade. The findings will aid in shaping effective regional economic policies and developing strategies to enhance trade relations, ultimately fostering stronger economic ties between Turkey and the Turkic Republics.