

T.C.
SAKARYA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI

TÜRKİYE'DE SERA GAZI EMİSYON DEĞERLERİNİN HİBRİT
MODEL İLE TAHMİNİ: EKONOMETRİ VE MAKİNE
ÖĞRENMESİ ORTAK YAKLAŞIMI

Mustafa KARAKUZU

YÜKSEK LİSANS TEZİ

Danışman: Prof. Dr. Hilal YILDIZ

TEMMUZ - 2024

T.C.
SAKARYA ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ

**TÜRKİYE’DE SERA GAZI EMİSYON DEĞERLERİNİN
HİBRİT MODEL İLE TAHMİNİ: EKONOMETRİ VE
MAKİNE ÖĞRENMESİ ORTAK YAKLAŞIMI**

YÜKSEK LİSANS TEZİ

Mustafa KARAKUZU

Enstitü Anabilim Dalı: Ekonometri

“Bu tez 08/07/2024 tarihinde online olarak savunulmuş olup aşağıdaki isimleri bulunan jüri üyeleri tarafından oybirliği ile kabul edilmiştir.”

JÜRİ ÜYESİ	KANAATİ
Prof. Dr. Hilal YILDIZ	Başarılı
Doç. Dr. Avni Önder HANEDAR	Başarılı
Doç. Dr. Gülten DURSUN	Başarılı

ETİK BEYAN FORMU

Enstitünüz tarafından Uygulama Esasları çerçevesinde alınan Benzerlik Raporuna göre yukarıda bilgileri verilen tez çalışmasının benzerlik oranının herhangi bir intihal içermediğini; aksinin tespit edileceği muhtemel durumda doğabilecek her türlü hukuki sorumluluğu kabul ettiğimi ve Etik Kurul Onayı gerektiği takdirde onay belgesini aldığımı beyan ederim.

Etik kurul onay belgesine ihtiyaç var mıdır?

Evet ☐

Hayır ☒

(Etik Kurul izni gerektiren araştırmalar aşağıdaki gibidir:

- Anket, mülakat, odak grup çalışması, gözlem, deney, görüşme teknikleri kullanılarak katılımcılardan veri toplanmasını gerektiren nitel ya da nicel yaklaşımlarla yürütülen her türlü araştırmalar,
- İnsan ve hayvanların (materyal/veriler dahil) deneysel ya da diğer bilimsel amaçlarla kullanılması,
- İnsanlar üzerinde yapılan klinik araştırmalar,
- Hayvanlar üzerinde yapılan araştırmalar,
- Kişisel verilerin korunması kanunu gereğince retrospektif çalışmalar.)

Mustafa KARAKUZU

08/07/2024

ÖN SÖZ

Mutlak doğru bilinemez. Mutlak doğru ile aramızdaki mesafe ancak mümkün olduğu kadarıyla alınan yol mertebesinde kapatılabilir. Bilim bu yolun kapatılmasında insanlığın sahip olduğu en önemli araçlardan biridir. Bu sebeple, öncelikle bu yolu mümkün edene, sonrasında bu yolun tüm yolcularına ve de yolcuların tüm destekçilerine teşekkürü borç bilirim.

Mustafa KARAKUZU

08/07/2024



İÇİNDEKİLER

KISALTMALAR	ii
TABLO LİSTESİ.....	iii
ŞEKİL LİSTESİ.....	iv
GRAFİK LİSTESİ.....	v
ÖZET	vi
ABSTRACT	vii
GİRİŞ.....	1
1. BÖLÜM: LİTERATÜR	7
1.1. Türkiye Üzerine Çalışmalar.....	7
1.2. Dünya Literatüründen Çalışmalar	9
2. BÖLÜM: VERİ VE YÖNTEM	12
2.1. Veri.....	12
2.2. Yöntem	13
2.2.1. Verilerin Birim Kök Analizi	13
2.2.2. Fourier Augmented Dickey Fuller (FADF) Birim Kök Testi	14
2.2.3. Augmented Dickey Fuller (ADF) Birim Kök Testi	15
2.2.4. Destek Vektör Makineleri (DVM).....	16
2.2.5. Otoregresif Hareketli Ortalama (ARMA)	21
2.2.6. Hibrit Yöntem.....	23
3. BÖLÜM: BULGULAR.....	24
SONUÇ	32
KAYNAKÇA.....	34
ÖZ GEÇMİŞ	37

KISALTMALAR

BMİDÇS	: Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi
KP	: Kyoto Protokolü
PA	: Paris Antlaşması
YSA	: Yapay Sinir Ağları
RMS	: Root Mean Square
RMSE	: Root Mean Squared Error
MBE	: Model Based Enrichment
MPE	: Mean Percentage Error
MAPE	: Mean Absolute Percentage Error
MAE	: Mean Absolute Error
MSE	: Mean Squared Error
OMHY	: Ortalama Mutlak Hata Yüzdesi
LR	: Lineer Regresyon
ANFIS	: Adaptive-Network Based Fuzzy Inference Systems
LSTM	: Long Short-Term Memory
GSYH	: Gayrisafi Yurtiçi Hasıla
SARIMA	: Seasonal Autoregressive Integrated Moving Average
FADF	: Fourier Augmented Dickey Fuller
ADF	: Augmented Dickey Fuller
DVM	: Destek Vektör Makineleri
DVR	: Destek Vektör Regresyonu
ARMA	: Autoregressive Moving Average
AR	: Autoregressive
MA	: Moving Average
ARCH	: Autoregressive Conditionally Heteroscedasticity

TABLO LİSTESİ

Tablo 1: Özet Literatür.....	11
Tablo 2: Kernel Fonksiyonları	21
Tablo 3: Fourier Augmented Dickey-Fuller Test Sonuçları.....	24
Tablo 4: Augmented Dickey-Fuller Birim Kök Test Sonuçları	24
Tablo 5: Kurgulanan Modellere Ait Hiperparametre Değerleri	25
Tablo 6: Performans Kriterleri Tablosu	25
Tablo 7: Destek Vektör Regresyonu Performans Ölçüm Değerleri	26
Tablo 8: AR, MA, ARMA Modelleri.....	26
Tablo 9: Hibrit ve DVR Tahmin Değerlerinin Karşılaştırılması.....	27

ŞEKİL LİSTESİ

Şekil 1: Makine Öğrenmesi Çeşitleri	16
Şekil 2: Destek Vektör Makinesi Sınıflandırma İşlemi.....	17
Şekil 3: Destek Vektör Regresyonu Kayıp Fonksiyonu	18
Şekil 4: Box-Jenkins Metodolojisi	22



GRAFİK LİSTESİ

Grafik 1: Dünya'da Sera Gazı Salınımlarının Seyri	2
Grafik 2: Sera Gazlarının Toplam İçindeki Payları.....	2
Grafik 3: 1990-2020 Yıllarına Ait Ortalama Sera Gazı Salınımlarına Göre Toplam Dünya Salınımındaki Paylar	4
Grafik 4: Serilerin Grafikselsel Gösterimi.....	13
Grafik 5: Eğitim Verilerine Ait RMSE Karşılaştırması.....	28
Grafik 6: Test Verilerine Ait RMSE Karşılaştırması	28
Grafik 7: Toplam Sera Gazı Serisi Tahmin Değerleri	29
Grafik 8: CO ₂ Gazı Serisi Tahmin Değerleri.....	30
Grafik 9: N ₂ O Gazı Serisi Tahmin Değerleri.....	30
Grafik 10: F Gazı Serisi Tahmin Değerleri	31

ÖZET	
Başlık: Türkiye’de Sera Gazı Emisyon Değerlerinin Hibrit Model ile Tahmini: Ekonometri ve Makine Öğrenmesi Ortak Yaklaşımı	
Yazar: Mustafa KARAKUZU	
Danışman: Prof. Dr. Hilal YILDIZ	
Kabul Tarihi: 08/07/2024	Sayfa Sayısı: vii (ön kısım) + 37 (ana kısım)
Her insanın parmak izinde bulunan farklılığa benzer şekilde her veri seti de kendine has özellikleri ihtiva eder. Bu sebeple veri analizi süreçlerinde, ele alınan veri setinin iyi anlaşılması gerekmektedir. Doğrusal veya doğrusal olmayan, durağan veya durağan olmayan yapıların tespit edilmesi ve buna göre bir yöntem oluşturulması, elde edilecek bulguların sıhhati açısından büyük önem arz edecektir. Aksi halde veri seti ile uyumsuz bir modelin kullanılmasıyla verinin genel eğilimi tespit edilemeyecek ve dolayısıyla bulgular ya eksik ya da büyük oranda hatalı olacaktır. Bahsi geçen bu durumdan kaçınmak için geliştirilmiş yöntemlerden biri olan hibrit yöntem ile verinin doğrusal ve doğrusal olmayan hareketlerine erişim mümkün hale gelmektedir, böylelikle analizin hata payı düşürülebilmektedir. Bu çalışmada günümüzün en önemli küresel problemlerinden biri olan sera gazı emisyonuna ilişkin toplam sera gazları, CO₂, N₂O ve F gazları serileri konu edinilmiş ve yukarıda ifade edilen hibrit yöntem aracılığı ile incelenmiştir. Türkiye için 1990-2021 yıllarını kapsayan veri seti, verinin yapısal durumunun tespiti adına görsel analize ve ardından Fourier Augmented Dickey Fuller (FADF) ve de Augmented Dickey Fuller testleri ile birim kök analizine tabi tutulmuştur. Doğrusal olmayan makine öğrenmesi tekniklerinden biri olan Destek Vektör Regresyonu (DVR) aracılığı ile öncelikle doğrusal olmayan eğilimlerin tespit edilebilmesi adına otoregresif bir yapı çerçevesinde model kurgulanmış ve modelin artıkları üzerinde de otoregresif hareketli ortalama yöntemi (ARMA) kullanılarak doğrusal hareketler tespit edilmeye çalışılmıştır. Elde edilen sonuçlar mutlak hata ortalaması, mutlak hata ortalamalarının yüzdesi, hata kareleri ortalaması ve hata kareleri ortalamasının karekökü kriterleri kullanılarak performans değerlendirmesinden geçirilmiştir. Bulgular ışığında Türkiye için sera gazları serilerinin doğrusal ve durağan bir yapı sergilemedikleri görsel ve de birim kök analizleri ile desteklenmiştir. Diğer taraftan serilerin tahmini için doğrusal ve doğrusal olmayan yöntemlerin birlikte kullanılmasının, daha düşük hataya sahip tahmin değerlerinin elde edilmesinde uygun bir yöntem olabileceği görülmüştür.	
Anahtar Kelimeler: Sera Gazları, İleri Dönük Tahmin, Ekonometri, Makine Öğrenmesi, Hibrit Yöntem	


ABSTRACT	
Title of Thesis: Forecasting Greenhouse Gases Emission With Hybrid Method in Turkey: The Common Approach of Econometrics and Machine Learning	
Author of Thesis: Mustafa KARAKUZU	
Supervisor: Prof. Dr. Hilal YILDIZ	
Accepted Date: 08/07/2024	Number of Pages: vii (pre text) + 37 (main body)
Every data set has own shape like being in human fingerprint. Because of that in the data analysis process, the data used in analysis has to be known with its detailed structure. Detecting the linear and nonlinear structures, stationary and unstationary structures also to create a process according to this detection has big importance aspect of the correctness of the findings. Otherwise, as a result of using unproper model with the data the general structure of the data would not be detected and thus the findings would be largely inaccurate or lack. With the hybrid method which developed to avoid from this problem to reach the linear and nonlinear structure of the data is available and then the accuracy rate of the model could increase. In this study subjects the total greenhouse gases, CO₂, N₂O and F gasses related with the carbon emission which the big issue of the recent decades and analysis these gasses with the hybrid method mentioned above. The data covering the period of 1990-2021 years for Türkiye is analysed with data visualization method firstly to detect the structural situation of the data and then with Fourier Augmented Dickey Fuller (FADF) and Augmented Dickey Fuller tests for unit root analysis. The model is firstly created with the support vector regression which one of them among the nonlinear machine learning methods within the framework of autoregressive structure to detect the nonlinear trends and then the autoregressive movement average method is employed with using the residuals of the support vector regression for detecting the linear trends of the data. The results obtained from the estimation are evaluated for performance using the criteria of absolute error mean, percentage of absolute error mean, mean square error and square root of the mean square error. According to the lights of the findings, it is understood by the visual and unit root analysis for Türkiye that the greenhouses gasses having the nonlinear and nonstationary structural situations. On the other hand it is seen that to obtain much more correct predicted outputs, to estimate the data using hybrid method can be more proper method contrary to the just using linear or nonlinear methods.	
Keywords: Greenhouses Gasses, Forecasting, Econometrics, Machine Learning, Hybrid Method	

GİRİŞ

Araştırmanın Konusu

İnsan yaşadığı doğadan bağımsız düşünülemez. İçinde var olduğumuz ve de varlığımızı devam ettirmekte olduğumuz tabiat ile olan ilişkimiz esasen kendi varlığımızla olan ilişkimizin yansımasıdır. Bu sebeple insanın ve dolayısıyla insanlığın devamı için bu ilişkinin en iyi biçimde kurulması gerekmektedir. İnsanlığın doğa ile olan bu ilişkisi tarihsel süreç içerisinde değerlendirildiğinde insanlığın bir parçası olduğu doğadan kopuş halinde olduğu ve doğal yaşantının yerini daha kültürel, bir diğer ifade ile yapay bir yaşam biçiminin aldığı anlaşılmaktadır. Öncelikle tabiata yüksek düzeyde uyum mecburiyetiyle başlayan hikayemiz, yaşanan teknik ilerlemeler sayesinde tabiat üzerinde gitgide artan oranda tasarrufta bulunabilmemizi ve yapay oluşumları inşa edebilmemizi sağlamıştır. Avcı-toplayıcı toplum yapısından sanayi toplumuna doğru giden bu hikâyede doğal yaşamdan kültürel yaşama doğru geçiş net bir şekilde fark edilebilmektedir. Doğadan elde edilen faydanın ihtiyaç temelli olduğu başlangıç aşamasından bugün gelmiş olduğumuz noktada ihtiyaçtan kat ve kat fazlasını elde etme hırsı ile donanmış kapitalist ekonomik sistemler gayet açıktır ki doğanın aşırı kullanımı ve israfına yol açmaktadır.


Sanayi devrimi ile hızlanan üretim yapısı, toplumların ekonomik refahlarını inşa ederken doğal kaynakların kullanımında da büyük bir artışa neden olmuştur. Özellikle insan nüfusunda yaşanan artış neticesinde, büyük oranda yenilenemez enerji kaynakları üzerine kurulu ekonomik düzenler, üretim ve talep döngüsünü devam ettirebilmek adına daha fazla enerji kullanımına gitmiştir. Petrol, doğal gaz ve kömür gibi yenilenemez enerji kaynaklarının kullanımındaki artış gayet tabi biçimde atmosferde bulunan sera gazlarının oranında daha yüksek bir noktaya ulaşılmasına sebebiyet vermiştir. Grafik 1 ile 1990-2020 yılları arasında Dünya’da yaşanan sera gazı emisyon değerlerindeki artış ifade edilmiştir.



Grafik 1: Dünya'da Sera Gazı Salınımlarının Seyri

Kaynak: Yazar tarafından oluşturulmuştur.

Küresel düzeyde sera gazı salınımlarındaki artış trendinin Türkiye açısından da deneyimlenmesi kaçınılmaz olmuştur. Grafik 2 ile Türkiye'ye ait çeşitli sera gazlarının toplam içindeki dağılımı verilmiştir. Buradan sera gazlarındaki artışın seyri görülebilmektedir.



Grafik 2: Sera Gazlarının Toplam İçindeki Payları

Kaynak: Yazar tarafından oluşturulmuştur.


Karbondioksit (CO_2), metan (CH_4), diazotmonoksit (N_2O) ve ozon (O_3) gibi gazlar sera gazları olarak nitelendirilmektedir. Bu gazlar Güneş ışınlarını tutucu bir kabiliyete sahip olduklarından atmosferde ısı birikimini sağlamaktadırlar. Bu gazların atmosferdeki artışı daha fazla ısı birikimine yol açar ve dolayısıyla küresel sıcaklıklarda artış yaşanır.

Paleoekoloji literatüründe Dünya'nın zaman zaman aşırı soğuk ve sıcak dönemlerinin olduğu ifade edilmesinin yanında bu döngüler, Dünya'nın kendi dinamizmi içerisinde gerçekleşen doğa olayları olarak anılmaktadır. Ancak küresel ısınmanın bir sorun olarak kabul edilmesi onun insan aktivitesi sonucunda meydana gelmesinden dolayıdır. Yenilenemez doğal kaynaklara bağımlı üretim ve tüketim döngüsü sonucunda atmosfere salınan sera gazları, Dünya'nın doğal döngüsüne bir yapay müdahale niteliğindedir (Türkeş, 2000: 187). Bu müdahale sonucu açığa çıkan bir diğer madde olan kükürtdioksit SO_2 kaynaklı sülfat SO_4 gibi aeroseller ise Güneş ışınlarını yeryüzüne ulaşmadan tutar ve geri yansır. Bu sebeple küresel açıdan ısınmanın değil soğumanın kaynağıdır. Ancak bu gazların atmosferdeki kalıcılık süreleri çeşitlilik gösterir ve bu uçucu parçacıklı yapıya sahip aeroseller birkaç gün ile birkaç hafta gibi bir sürede kaybolurlar. Bu süre ısıma etkisine sahip diğer gazlara göre ise oldukça kısadır. Buradan açıkça anlaşıldığı üzere yapay müdahalenin ağır basan niteliği ısınma yönünde olmaktadır. Sıcaklık artışı, buzulların erimesi ve deniz seviyesindeki yükselme gibi başlıca problemleri ortaya çıkaran küresel ısınma olgusu, bugün vardığımız bu noktada, tüm salınımın kesilmesi mümkün olsa dahi hali hazırda atmosferde birikmiş olan sera gazlarının etkisi sonucunda, günümüz itibarıyla yaşadığımız iklim farklılaşması ve de söz konusu birikimin gelecek dönemlerde meydana getireceği etki yadsınamaz (Türkeş, 2008: 26).

Bahsi geçen antropojen zorlamayla meydana gelen bu yapay müdahalelerin kontrol altına alınması ve hatta terk edilmesi hususunda çeşitli çalışmalar yapılmaktadır. Bunlardan en önemlisi 1992 yılında Rio de Janeiro'da imzalanan ve 1994 yılında yürürlüğe giren Birleşmiş Milletler İklim Değişikliği Çerçeve Sözleşmesi (BMİDÇS) olup uluslararası alanda icra edilmiş ilk çalışma niteliğindedir. Eşitlik, ortak fakat farklılaştırılmış sorumluluk, ihtiyatlılık ve sürdürülebilir kalkınmayı destekleme hakkı ve yükümlülüğü ilkelerine dayanarak oluşturulan sözleşme, gelişmiş, gelişmekte olan ve gelişmemiş ülkelerin tarihsel süreç içerisinde iklim sorununa katkılarını esas alması bakımından da oldukça kapsayıcı bir yapıdadır. Bu sözleşmeye taraf olmayı her aşamada istemiş olan Türkiye, sözleşmede gelişmiş ülkelerle aynı statüde kabul edilerek aynı sorumluluklara tabi tutulmak zorunda bırakılmasına şiddetle karşı çıkmıştır. İtirazlar nihayet kabul edilmiş ve 2004 yılında Türkiye, sözleşmede kendisine özel statü verilen tek ülke olarak yerini almıştır (Öztürk, M., & Öztürk, A., 2019: 527). Bir diğer çalışma olan Kyoto Protokolü (KP), gelişmiş ve gelişmekte olan ülkelerin sera gazı salınımı konusunda

ortaklaşa hareket etmeleri için 1997 yılında düzenlenmiş ancak 2005 yılında yürürlüğe girmiştir. Türkiye'nin KP'ye dahil olması 2009 yılında gerçekleşmiştir. KP'nin başlıca amaçlarından biri sera gazı salınımını, bu protokolü imzalayan ülkeler için 1990 yılına kıyasla 2008-2012 dönemi için yüzde 5, 2013-2020 dönemi için yüzde 18 oranında azaltmaktır. Bu protokol sebebi ile Türkiye'nin sera gazı salınımını azaltma yükümlülüğü bulunmamaktadır (Türkeş, 2006: 99). Bir diğer antlaşma, Paris Antlaşması (PA) olarak adlandırılmaktadır. PA, 2015 yılında Paris'te düzenlenen BMİDÇS 21. Taraflar Konferansı'nda kabul edilmiş ve 2016 yılında yürürlüğe girmiştir. İlk kez küresel ölçekte tüm ülkelerin 2030 yılına kadar sera gazı azaltımı taahhüdünde bulunması hasebiyle antlaşma tarihsel açıdan büyük öneme sahiptir. Türkiye taraf olduğu bu antlaşma dolayısıyla 2030 yılına kadar yüzde 21 oranında artışta azaltım niyetinde bulunmuştur. Ancak 2022 yılında düzenlenen bir oturumda Türkiye artıştan azaltım hedefini yüzde 41 düzeyine yükseltmiştir (Karakaya, 2016: 1).

Yapılan antlaşmaların adalet ilkesi çerçevesinde yapılması ve yürütülmesi oldukça önemlidir. Bu küresel probleme her ülkenin katkısının aynı olmadığı da açıktır. Grafik 2'ye ait veriler Dünya Bankası (World Bank Open Data) veri paylaşım sisteminden edinilmiştir. Verileri 1990-2020 yıllarına ait olup görselleştirme aşamasında bu 30 yıllık süre içerisinde ortalama olarak en fazla sera gazı salınımına sebep olmuş ilk 20 ülke belirlenmiştir. Aynı dönem için küresel sera gazı salınımı ortalaması içerisindeki payları hesaplanarak görselleştirilmiştir.



Grafik 3: 1990-2020 Yıllarına Ait Ortalama Sera Gazı Salınımlarına Göre Toplam Dünya Salınımındaki Paylar

Kaynak: Yazar tarafından oluşturulmuştur.

Grafik 3 yardımı ile görüleceği üzere ortalamada en fazla paya sahip ilk 4 ülke olan Birleşik Devletler, Çin, Rusya Federasyonu ve Hindistan yüz ölçümü açısından geniş topraklara sahip olmakla birlikte sanayi üretimi açısından da diğer ülkelere nazaran daha yüksek kapasiteye sahiplerdir. Grafikte herhangi bir gelişmemiş ülke de bulunmamaktadır. Buradan hareketle BMİDÇS'nin sorumluluğun emisyonu azaltmak noktasında ortak olması ancak her ülkenin tarihsel süreç içerisinde bu probleme yaptığı olumsuz katkı oranında emisyonu azaltma sorumluluğuna tabi tutulması anlamını taşıyan “ortak fakat farklılaştırılmış sorumluluk” ilkesi çok daha açıklık kazanmaktadır.

Araştırmanın Amacı

Uluslararası çalışmalarla ortak bir hedef belirlenmesi, ülkelerin sorumluluklarına sahip çıkması ve gerekenlerin yapılması önemlidir. Bir diğer taraftan yapılan antlaşmalara uyulduğu sürece olumlu sonuçlar görülebileceği de aşîkardır. Ancak söz konusu hedeflere doğru gidilirken politikaların tutarlığının gözlenmesi ve gereken tedbirlerin alınması adına bilimsel araştırmaların yapılması elzemdir. Bu sebeple çalışmada toplam sera gazları, CO₂, N₂O, ve F gazlarının tahmini yapılmıştır ve de ileri dönük değerler kestirilmiştir. Tarafımızca tespit edilen çalışmaların çoğunlukla makine öğrenmesinin çeşitli doğrusal veya doğrusal olmayan modelleri ile kurgulandığı görülmüştür. Ekonometrik açıdan ise ilgili konu ileri dönük tahmin amaçlı değil emisyon değerlerini etkileyen değişkenler ve aralarındaki ilişki üzerine kurgulanmıştır. Bu çalışmada ise ekonometri ve makine öğrenmesi arasında ortak bir yaklaşım kurgulanarak literatüre katkı yapmak amaçlanmıştır.

Araştırmanın Önemi

Doğrusal ve doğrusal olmayan tahmin araçlarının bir arada kullanıldığı hibrit modellerde hangi aracın öncelikle kullanılması gerektiği konusunda metodolojik bir yaklaşım sunması açısından birim kök testlerinin uygulanabileceğini gösteren çalışmanın önemi buradan kaynaklanmaktadır.

Araştırmanın Yöntemi

Öncelikle serilerin doğrusallık ve durağanlık analizleri grafik ve birim kök testleri yardımıyla analiz edilmiştir. Birim kök testleri ile yalnızca serilerin seviyesinde durağan

olup olmadıkları anlaşılmaya çalışılmış ve bu bilgi sayesinde uygulanan metodolojide kullanılan modeller arasında bir öncelik belirlenmeye çalışılmıştır. Serilerin seviyesinde durağan olması halinde önceliğin, doğrusal veri setlerine daha uyumlu modele aksi halde doğrusal olmayan veriye daha uygun modele verilmesi hedeflenmiştir. Böylece seviyesinde durağan olmayan serinin durağan hale getirilmesi için farkının alınması zorunluluğundan kaçınılarak serilerin uzun dönem bilgi kaybına uğraması engellenmek istenmiştir. Ortak yaklaşım çerçevesinde kurgulanan hibrit model yardımı ile bir veri setinin doğrusal ve doğrusal olmayan bileşenleri ayrı ayrı ele alınarak tahmin değerlerinde bir iyileşme sağlamak hedeflenmiştir. Bir makine öğrenmesi yöntemi olan destek vektör regresyonu ile bir istatistiksel öğrenme yöntemi olan otoregresif hareketli ortalama yöntemi uygulanmış olup 1990-2021 yıllarına ait veriler analiz edilmiştir. 2022-2030 yıllarına dair ileri dönük tahmin değerlerine ulaşılmıştır.

Çalışmanın birinci bölümünde literatürde yer alan ilgili çalışmalara yer verilmiştir. İkinci bölümde, kullanılan veriye dair bir analiz sunulmuş ardından geleceğe dönük tahmin yönteminde kullanılacak metodun detaylı açıklaması yapılmıştır. Üçüncü bölümde elde edilen bulgular gösterilmiştir. Son olarak dördüncü bölümde araştırmadan çıkarılan sonuçlara yer verilerek çalışma tamamlanmıştır.

1. BÖLÜM: LİTERATÜR

1.1. Türkiye Üzerine Çalışmalar

Sözen, Gülseven ve Arcaklioğlu'nun 2007 yılına ait sektörel enerji tüketim verilerine dayanarak toplam sera gazı emisyonunu tahmin etmeye çalıştıkları araştırmalarında yapay sinir ağları (YSA) yöntemi kullanarak 0.999997 gibi oldukça yüksek bir güvenilirlik sağlayan R2 değeri elde etmelerinin yanı sıra 0.001162 RMS değeri hesaplamışlardır (Sözen vd., 2007: 6491).

Bakay ve Ağbulut'un 2021 yılı çalışmalarında 1990-2014 yıllarını kapsayan elektrik üretimi verileri kullanılarak sera gazlarına ait 2015-2018 yıllarına ilişkin emisyon değerleri tahmin edilmeye çalışılmıştır. Destek vektör regresyonu, yapay sinir ağları ve derin öğrenme gibi üç farklı makine öğrenmesi yöntemi kullanan yazarlar toplam sera gazı emisyonu bakımından en yüksek R2 değerine sahip olan modelin derin öğrenme modeli olduğunu belirtmişlerdir. Bu model için R2, RMSE, MBE değerleri sırasıyla 0.998, 2.046, 0.419 olarak belirtilmiştir (Bakay, Ağbulut, 2021: 125324).

Akyol ve Uçar, 2020 yılı çalışmalarında nüfus, elektrik tüketimi, gayri safi yurtiçi hasıla ve elektrik üretim serilerini kullanarak 1990-2017 verileri eğitim ve 2009-2011, 2012-2014, 2015-2017 verileri test veri seti olmak üzere lineer regresyon, yapay sinir ağları ve destek vektör regresyonu modellerini kurgulayarak karbon ayakizi serisi hakkında ileri dönük tahmin yapmışlardır. Üçer dönemlik tahminlerini MPE ve MAPE performans kriterleri ile değerleyen yazarlar bu üçer dönemlik tahmin sonuçlarının ortalamasını alarak kurgulamış oldukları modelleri kıyas etmişlerdir. Elde edilen sonuçlara göre lineer regresyon için ortalama MAPE 13.3842, yapay sinir ağları modeli için 2.3406 ve destek vektör regresyonu için 1.8888 değerleri rapor edilmiştir (Akyol, Uçar, 2021: 38552-38562).

Sözen, Gülseven ve Arcaklioğlu 2009 yılı çalışmalarında sektörel enerji tüketimi, gayrisafi yurtiçi hasıla ve gayrisafi milli hasıla verilerine dayanarak sera gazı emisyonu serisini yapay sinir ağları modeli ile tahmin etmişlerdir. Çalışmada üç ayrı model kurgulanmış olup birinci model için sektörel enerji tüketimi verisi girdi olarak alınmış, ikinci modelde gayrisafi yurtiçi hasıla ve nüfus serileri girdi olarak alınmış ve son olarak üçüncü modelde gayrisafi milli hasıla ve nüfus serileri yapay sinir ağı kurgusunda girdi olarak alınmıştır. Her üç model için sera gazı emisyonu çıktı olarak kullanılmıştır. Sekiz

katmanlı bir yapıda sinir ağını kurgulayan yazarlar bu üç model içerisinde en iyi sonucu birinci modelin verdiğini ifade etmişlerdir. Birinci model için R^2 0.999997, MAPE 0.147151 ve RMS 0.001162 değerleri hesaplanmıştır (Sözer vd., 2009: 1141-1159).

Hamzacebi ve Karakurt 2015 yılı çalışmalarında gri tahminleme yöntemini kullanarak enerji ile ilişkili olan karbondioksit salınımı verisi üzerinde tahminde bulunmuşlardır. 1965-2001 yıllarını eğitim verisi olarak kullanan yazarlar iki farklı düzeyde ileri dönük tahminleme yapmışlardır. Bunlardan biri yıllık veri tahmini yönünde olup diğeri beş yıllık dönemleri tahmin etmeye yöneliktir. Yıllık tahmin senaryosunda 2002-2012 yılları test verisi olarak kullanılmış ve doğruluk performans değerleri MAE için 25.165, MAPE için 0.09 olarak bulunurken beş yıllık tahmin senaryosunda bu değerler sırası ile 26.408 ve 0.096 olarak hesaplanmıştır (Hamzacebi, Karakurt, 2015: 1023-1031).

Köne ve Büke 2010 yılı çalışmalarında Türkiye'nin de içinde bulunduğu ilgili dönemde, karbondioksit salınımında en çok paya sahip ilk 25 ülkenin emisyon verilerini kullanarak trend analizi gerçekleştirmişlerdir. 1971-2007 yıllarını kapsayan enerji kaynaklı karbon dioksit salınımı veri seti ile analizlerini gerçekleştiren yazarlar Türkiye için kurguladıkları modelin R^2 değerini 0.9627, eğim katsayısını ise 5.481 olarak hesaplamışlardır (Köne, Büke, 2010: 2906-2915).

Şişeci Çeşmeli ve Pençe 2019 yılı çalışmalarında Poisson regresyonu, lineer regresyon (LR), yapay sinir ağları, adaptif ağ tabanlı bulanık çıkarım sistemi (ANFIS) ve uzun-kısa vadeli hafıza (LSTM) gibi çeşitli makine öğrenmesi yöntemleriyle 1967-2017 yılı sera gazı salınımı veri setini tahmin etmişlerdir. Bu çalışmada 1967-2001 yılları eğitim, 2002-2017 yılları ise test veri seti olarak ayrıştırılmıştır. Elde edilen sonuçlar 10-kat çapraz doğrulama tekniği aracılığı ile değerlendirilmiş olup modeller arasında LSTM uygulamasının 0.02 RMSE, 0.75 MAPE ve 1.0 R^2 değerlerine sahip olması dolayısıyla diğer modeller arasında en iyi sonuçlara sahip model olduğu ifade edilmiştir (Çeşmeli, Pençe, 2020: 332-348).

Pabuçcu ve Bayramoğlu 2016 yılı çalışmalarında yapay sinir ağları modelini kullanarak 2020-2025-2030 yılları için CO₂ salınımı verisini tahmin etmişlerdir. Girdi olarak nüfus, GSYH, enerji üretimi ve tüketimi ve ulaşım için enerji kullanımı verilerini kullanarak yapılan model kurgusunda 0.0054 MSE ve 0.1614 RMSE değerlerine ulaşılmıştır (Pabuçcu, Bayramoğlu, 2016: 762-778).

Boğar ve Özsüt Boğar 2017 yılı çalışmalarında yapay sinir ağı yöntemi ile enerji, endüstriyel işlemler ve ürün kullanımı, tarımsal faaliyetler ve atıklar olmak üzere dört farklı sektörü dikkate alarak CO₂ salınımı verilerini 2016-2030 yılları için tahmin etmişlerdir. Yapılan çalışmada nüfus, GYSH, enerji tüketimi ve ulaşım için kullanılan enerji serileri girdi olarak ele alınmış olup 1990-2015 yıllarını kapsamaktadır. 1990-2011 yıllarına ait verileri eğitim ve 2012-2015 yıllarına ait verileri ise test amacıyla kullanan yazarlar R² ve ortalama mutlak hata yüzde kriterlerini model performans ölçümü için kullanmışlardır. Elde edilen sonuçlara göre enerji sektörü için kurgulanan model için 0.3509 değerinde OMHY bulgusu ifade edilirken endüstri sektörü, tarım sektörü ve atık sektörü için OMHY değerleri sırasıyla 0.4411, 0.1191, 0.1228'dir (Boğar, Özsüt Boğar, 2017: 15-27).

Kayakuş, Terzioğlu, Erdoğan, Aygen Zetter, Kabas ve Moiceanu 2023 yılı çalışmalarında yapay sinir ağı, destek vektör regresyonu ve çok değişkenli doğrusal regresyon yöntemleri aracılığıyla 1990-2020 yıllarını kapsayan veri setini kullanarak karbon emisyonunu tahmin etmişlerdir. Kurgulanan modelde nüfus, GSYH, kişi başına elektrik tüketimi, toplam enerji içerisindeki yenilenebilir enerji, kömür, doğal gaz ve sıvı yakıtların payı, içten yanmalı motorlu araç sayısı, sanayi üretim endeksi, sığır sayısı, toplam tarım arazisi ve toplam ormanlık alan miktarlarına ait seriler girdi olarak kullanılmıştır. Hesaplanan doğruluk kriterlerine göre en güçlü tahmin gücüne sahip modelin 0.013 RMSE ile destek vektör regresyonu olduğu ifade edilirken yapay sinir ağı ve çoklu doğrusal regresyon için RMSE değerleri sırasıyla 0.019 ve 0.016 olarak bulunmuştur (Kayakuş vd., 2023: 13025).

1.2. Dünya Literatüründen Çalışmalar

Jena vd. 2021 yılı çalışmalarında karbondioksit salınımına en fazla sebep olan ilk 17 ülke için çok katmanlı yapay zekâ modeli kullanarak tahminde bulunmuşlardır. Ülkeler %2 ve daha fazla oranda salınım katkıda bulunanlar ile %1'den az bulunanlar olarak iki gruba ayrılmıştır. İçlerinde Türkiye'nin bulunduğu bu çalışmada 1960-2016 yılları arasını kapsayan veri seti kullanılmıştır. Yapay zekâ modelinde GSYH, ticaret oranı ve şehirli nüfus değişkenleri girdi olarak kullanılmıştır. Performans ölçüm kriterleri olarak MAPE, MAE ve RMSE kullanılmış olup test veri seti için bu değerler sırasıyla 2.1538, 0.0162 ve 0.0209'dur (Jena vd., 2021: 6336).

Masan vd. 2018 yılı çalışmalarında İrlanda için enerji talebi, rüzgâr enerjisi ve karbondioksit salınımı verilerini tahmin etmişlerdir. Bu çalışmada dördü yapay sinir ağlarına ait çeşitli algoritmalar olmak üzere toplam yedi farklı model kurgulanmıştır. Otoregresif bir yapıyla kurgulanan modeller içerisinde karbondioksit salınımına ilişkin test verisi üzerinde en düşük hata değerlerine sahip model 7.29 MAE, 109.1 MSE, 10.45 RMSE ve 2.140 MAPE ile doğrusal regresyon modeli olmuştur (Mason vd. 2018: 705-720).

Geevaretnam vd. 2022 yılı çalışmalarında 92 ülkenin CO2 salınımı değerlerinin toplamı üzerinden elde ettikleri veri setini kullanarak tahmin yapmışlardır. Yapay sinir ağları, rasgele orman ve destek vektör regresyonu gibi makine öğrenmesi yöntemleri aracılığıyla, 1965-2020 yılı verileri analiz edilmiştir. Petrol, kömür ve gaz tüketim serileri CO2 salınım değerlerini tahmin etmek adına bağımsız değişkenler olarak kurguya eklenmiştir. Elde edilen sonuçlar neticesinde doğrusal kernel fonksiyonu ile kurgulanan modelin diğer makine öğrenmesi yöntemlerine kıyasla 22.030 MAE, 36.3161 RMSE ve 0.0736 MAPE değerlerine sahip olması sebebiyle daha etkin bir model olduğu tespit edilmiştir (Geevaretnam vd., 2022: 17-23).

Meng ve Noman 2022 yılı çalışmalarında global CO2 salınımı serisi üzerinde tahminde bulunmuşlardır. Çalışmada mevsimsel otoregresif hareketli ortalama (SARIMA) yöntemi, makine öğrenmesi metodolojisine ait olan serilerin eğitim ve test veri setlerine ayrılması hususuna dikkat edilerek kullanılmıştır. Pandemi dönemini dikkate alarak dört farklı zaman aralığı ile dört farklı model kurgulayan yazarlar, 1975-2018 için pandemi öncesi, 1975-2019 için pandemi dönemi, 1975-2021 için geçiş dönemi ve son olarak 1975-2022 için pandemi sonrası dönem adlandırmasında bulunmuşlardır. Bu dört farklı dönem için kurgulanan modellerden en düşük hata payına sahip modelin pandemi sonrası döneme ait olup 0.09 MAPE değerine sahip olduğu ifade edilmiştir (Meng, Noman, 2022: 1871).

Namboori'nin 2020 yılı çalışmasında Birleşik Devletler'e ait karbon salınım verileri analiz edilmiştir. Destek vektör regresyonu, otoregresif hareketli ortalama ve Prophet yöntemleri kullanılarak yapılan analizde 1973-2019 yıllarına ait veriler ele alınmıştır. Üç farklı seri için yapılan modellemelerde RMSE, MAE ve MAPE performans ölçüm kriteri olarak kullanılmıştır. Elde edilen bulgular ışığında Prophet modelinin en iyi performans ölçümlerine sahip olduğu kaydedilmiştir (Namboori, 2020).

Araştırmacılar	Araştırmaya Konu Coğrafya	Kullanılan Model
Sözen vd. (2007)	Türkiye	Yapay Sinir Ağları
Bakay ve Akbulut (2021)	Türkiye	Destek Vektör Regresyonu Yapay Sinir Ağları Derin Öğrenme
Akyol ve Uçar (2020)	Türkiye	Lineer Regresyon Yapay Sinir Ağları Destek Vektör Regresyonu
Sözen vd. (2009)	Türkiye	Yapay Sinir Ağları
Hamzacebi ve Karakurt (2015)	Türkiye	Gri Tahminleme
Köne ve Büke (2010)	Türkiye ve 24 Diğer Ülke	Trend Analizi
Şişeci Çeşmeli ve Pençe (2019)	Türkiye	Poisson Regresyon Lineer Regresyon Yapay Sinir Ağları Adaptif Ağ Tabanlı Bulanık Çıkarım Uzun-Kısa Vadeli Hafıza Modeli
Pabuçcu ve Bayramoğlu (2016)	Türkiye	Yapay Sinir Ağları
Boğar ve Özsüt Boğar (2017)	Türkiye	Yapay Sinir Ağları
Kayakuş vd. (2023)	Türkiye	Yapay Sinir Ağları Destek Vektör Regresyonu Çok Değişkenli Doğrusal Regresyon
Jena vd. (2021)	Türkiye ve Diğer 16 Ülke	Çok Katmanlı Yapay Zeka Modeli
Masan vd. (2018)	İrlanda	Yapay Sinir Ağları
Geevaretnam vd. (2022)	92 Ülke	Yapay Sinir Ağları Rasgele Orman Destek Vektör Regresyonu
Meng ve Noman (2022)	Küresel	Mevsimsel Otoregresif Hareketli Ortalama
Namboori (2020)	Birleşik Devletler	Destek Vektör Regresyonu Otoregresif Hareketli Ortalama Prophet

Tablo 1: Özet Literatür


Kaynak: Yazar tarafından oluşturulmuştur.


İncelenen çalışmaların büyük çoğunluğu makine öğrenmesi ve istatistiksel öğrenme yöntemlerinin birden fazla çeşidinin tek bir çalışmada kullanılması ve modeller arasındaki performans ölçümlerinin değerlendirilmesi şeklinde kurgulandığı görülmüştür. Söz konusu çalışmalar, salınım değerlerinin tahmininde serilerin geçmiş değerlerini kullanmak yerine genellikle başkaca bağımsız değişkenleri kullanmıştır. Bu çalışma makine ve istatistiksel öğrenme arasında ortak bir yaklaşım sunarak ve aynı zamanda verinin kendi geçmiş değerleri üzerine model kurgusuna sahip olarak literatüre katkı sağlamaktadır. Ekonometrik yöntemlerin gelecek değer tahminlerinde pek kullanılmadığı göze çarpmaktadır. Bu açıdan birim kök testlerinin, model kurgusunda sürece dahil edilmesi açısından literatüre bir diğer katkı sağlandığı düşünülmektedir.

2. BÖLÜM: VERİ VE YÖNTEM

2.1. Veri

Çalışmada kullanılan zaman serileri 1990-2021 yıllarını kapsamakta olup Türkiye İstatistik Kurumu tarafından düzenlenmiş yıllık periyota sahip verilerdir. Grafik 4, verilerin yapısal durumlarının ifade edilebilmesi adına eğim denklemleri ve uyum iyiliği değerleri ile gösterilmiştir. Üstel, doğrusal, logaritmik ve polinomsal denklemlerden en yüksek uyum iyiliği değerini veren matematiksel denklem seçilerek gösterime dahil edilmiştir.





Grafik 4: Serilerin Grafiksel Gösterimi

Kaynak: Yazar tarafından oluşturulmuştur.

Tüm serilerde ikinci dereceden polinomsal denklemin üstel, doğrusal ve logaritmik denklemlere göre daha yüksek uyum iyiliği değerine sahip olduğu tespit edilmiştir. Buradan hareketle görsel analizin, veriler hakkında doğrusal olmayan bir yapıya işaret ettiği söylenebilir. Son olarak elde edilen veriler, model kurgusuna geçilmeden önce ortak bir ölçüm düzeyine indirgenmek amacıyla $(x_i - \bar{x})/x_{std}$ formülasyonu kullanılarak normalize edilmiştir.

2.2. Yöntem

2.2.1. Verilerin Birim Kök Analizi

Bir veri setinden bilgi edinilmek istendiğinde bu veri setinin yapısal durumu hakkında ön bilgiye sahip olmak büyük önem arz eder. Dolayısıyla veri setindeki yapısal durumun analizi ve teşhisi yapılacak işlemler açısından ilk sırada yer almaktadır. Elimizdeki veri setinin durağan olup olmadığına dair yapılacak bir inceleme, veri setinin yapısı hakkında bize bilgi verecektir.

Ekonometri biliminin temel saç ayaklarından biri olan birim kök analizi, zaman serilerinin yapısal durumunun incelenebilmesi için imkân vermektedir. Literatürde birçok birim kök analiz metodu bulunmakla birlikte bu metotların her birinin temel amacı, serilerin durağan bir sürece sahip olup olmadığını anlamaktır. Bir diğer ifade ile serinin ortalamasının ve varyansının zaman içinde değişip değişmediğini tespit etmektir (Gujarati, 2022). Zaman serilerinin analizinde kullanılan birçok ekonometrik yöntem serilerin durağanlık koşullarına karşı katı kurallar getirmektedir. Öyle ki durağanlık koşulunun sağlanmaması halinde ilgili seri ekonometrik analizde kullanılamaz hale gelebilmektedir. Aksi bir durum olarak durağanlık şartı sağlanmamış bir serinin analize

dahil edilmesi ise sahte regresyon problemini meydana getirmektedir (Granger, Newbold, 1974: 111-120).

Durağanlığın birçok ekonometrik analiz için katı bir varsayım olması hasebiyle bir serinin seviye durumu durağan değilse ilgili yöntemin kullanılması, çoğu zaman serinin durağanlaştırılmasından geçmektedir. Ancak seviyesinde durağan olmayan bir seri birinci veya ikinci farkı alınarak durağan hale getirildiği takdirde uzun dönem bilgisinde kayıp yaşanmaktadır. Arzu edilen optimal yöntem ise serilerin seviyesi ile işlem yapabiliyor olmaktır. Çalışmada uygulanan yöntem, serileri uzun dönem bilgi kaybına uğratmadan tahmin edebilmek üzerine kurulmuştur. Bu sebeple serilerin seviye hallerinde durağan olup olmadıklarını tespit edebilmek üzere çeşitli birim kök testleri uygulanmıştır.

2.2.2. Fourier Augmented Dickey Fuller (FADF) Birim Kök Testi

Bir serideki yapısal kırılmanın tespitiyle birlikte birim kök analizinin de yapılabilmesini mümkün kılan FADF birim kök testi en basit tanımı ile klasik yöntem olan Augmented Dickey Fuller (ADF) birim kök testinin Fourier denklemleri ile genişletilmiş halidir. Seride yumuşak yapısal kırılmaların tespiti, modelde bulunan sinüs ve kosinüs fonksiyonları aracılığı ile gerçekleştirilmektedir. Sabit ve deterministik trend içeren model, 1 numaralı denklemde görülmektedir. 2 numaralı denklemde ise t 'nin deterministik fonksiyonu açılmış olup sinüs ve kosinüs fonksiyonları detaylı biçimde ifade edilmiştir. Yumuşak yapısal kırılmaları tespit edebilme kabiliyetine sahip bu fonksiyonlar içerisinde bulunan t ile trend değerleri, T ile örneklem büyüklüğü ve son olarak k ile uygun frekans sayısı belirtilmektedir. $1 \leq k \leq 5$ aralığı uygun frekans değer aralığını vermektedir (Enders, Lee, 2012: 196-199).

$$y_t = a(t) + \rho y_{t-1} + \gamma t + \varepsilon_t \quad (1)$$

$$a(t) = a_0 + \sum_{k=1}^n a_k \sin\left(\frac{2\pi kt}{T}\right) + \sum_{k=1}^n \beta_k \cos\left(\frac{2\pi kt}{T}\right); \quad n \leq T/2 \quad (2)$$

$$\Delta y_t = \rho y_{t-1} + c_1 + c_2 t + c_3 \sin\left(\frac{2\pi kt}{T}\right) + c_4 \cos\left(\frac{2\pi kt}{T}\right) + e_t \quad (3)$$

Nihai olarak 3 numaralı denklem ile birim kök testi uygulanmaktadır. Temel hipotez $H_0 = \rho = 1$ olarak verilmektedir. Bu noktada elde edilen sonuçların sıhhati, sinüs ve kosinüs fonksiyonlarına ait c_3 ve c_4 katsayılarının istatistiksel olarak anlamlı olup olmadığına bağlıdır. Anlamlılık testi için c_3 ve c_4 katsayılarına F kısıt testi uygulanmaktadır. Bulunan F değeri Enders ve Lee'nin çalışmalarında sunmuş oldukları F tablo değerleri ile kıyas edilmektedir. Kıyas neticesinde c_3 ve c_4 katsayıları anlamlı bulunursa ρ katsayısına

ilişkin bulgular geçerli olacak aksi halde ise klasik birim kök testi olan ADF'nin uygulanması gerekecektir.

2.2.3. Augmented Dickey Fuller (ADF) Birim Kök Testi

Klasik bir test olan ADF bu alanın ilk testlerinden olmasına rağmen günümüz bilimsel literatüründe halen büyük oranda kullanılmaktadır. Dickey ve Fuller 1979 yılı çalışmalarında geliştirmiş oldukları testi, hata terimleri arasındaki ilişkiyi yani otokorelasyonu giderebilmek amacıyla bağımlı değişkenin gecikmeli değerleriyle tekrardan kurgulamışlardır. Bu süreç sonucunda genişletilmiş bir forma kavuşan test literatürde yerini almıştır.

$$Y_t = \alpha + \beta t + \rho Y_{t-1} + e_t \quad (4)$$

4 numaralı denklemde ADF için sabit ve deterministik trendin bir arada bulunduğu en geniş model gösterilmiştir. α sabit katsayısını ve β deterministik trend katsayısını ifade etmektedir (Dickey, Fuller, 1979: 427-431, 1981: 1057-1072).

$$\Delta Y_t = \alpha + \beta t + \delta Y_{t-1} + e_t; \quad \delta = (\rho - 1). \quad (5)$$

$$H_0 = \delta \geq 0; \text{ Seri seviyesinde durağan değildir. } I(1)$$

$$H_1 = \delta < 0; \text{ Seri seviyesinde durağandır. } I(0)$$

5 numaralı denklemde yer alan δ katsayısının ilgili tablo değerleri ile kıyas edilmesi sonucunda şayet hesap değeri tablo değerini aşması durumu söz konusu ise yukarıda ifade edilen temel hipotez reddedilir. Dolayısıyla seri de birim kök olmadığı yönünde bir bulgu elde edilmiş olur ve serinin seviyesinde durağan olduğu bir diğer gösterim ile $I(0)$ olduğu ifade edilir.

$$\Delta^2 Y_t = \alpha + \beta t + \delta \Delta Y_{t-1} + e_t \quad (6)$$

$$H_0 = \delta \geq 0; \text{ Seri birinci derecen durağan değildir. } I(2)$$


$$H_1 = \delta < 0; \text{ Seri birinci dereceden durağandır. } I(1)$$

Aksi durumda ise fark alma işlemi tekrar edilir ve 6 numaralı denkleme ulaşılır. Benzer şekilde δ katsayısı istatistiksel teste tabi tutulur. Temel hipotezin reddedilmesi halinde serinin birinci derecen durağan olduğu yönünde karar verilir. Diğer durum bu serinin ikinci derecen durağan olabilme ihtimalini ifade eder ki bu tür seriler ekonometrik açıdan çoğu zaman kullanışsız serilerdir.

2.2.4. Destek Vektör Makineleri (DVM)

Makine öğrenmesi yöntemleri iki ayrı başlık altında sınıflandırılmaktadır. Bunlar denetimli öğrenme ve denetimsiz öğrenmedir. Söz konusu ayrım, işleme tabi tutulan verinin mahiyetine göre yapılmaktadır. Şayet elimizdeki veri seti herhangi bir etikete sahip değilse bir diğer ifade ile işlem öncesinde verinin ne olduğu hakkında bir bilgi yok ise bu aşamada denetimsiz öğrenme yöntemleri devreye girmektedir. Diğer taraftan elimizdeki verinin daha önceden belirlenmiş bir etiketi olması halinde ise denetimli öğrenme yöntemlerine başvurulmaktadır.


Denetimli öğrenme yöntemleri işleme tabi veri setinin eğitim ve test verisi olarak iki kısma ayrılmasını gerektirmektedir. Eğitim için ayrılan veri seti modelin öğrenme aşamasında kullanılırken test veri seti modelin öğrenme aşamasındaki performansının denetimi için kullanılır. Bu sebeple bahsi geçen yöntem, denetimli öğrenme olarak adlandırılmaktadır (Çağlayan Akay, 2020).



Şekil 1: Makine Öğrenmesi Çeşitleri

Kaynak: Çağlayan Akay, E., (2020).

İki farklı denetimli öğrenme yöntemi olduğu Şekil 1’de görülmektedir. Sınıflandırma, çıktıları kategorik değişkenler olan kesikli veri setlerine uygulanarak veri setinin özellikleri itibarıyla sınıflandırılmasını, ayrıştırılmasını ifade eder. Regresyon ise sürekli değişkenler ile kurulan ve çıktıları sayısal değerler olan bir öğrenme sürecini ifade eder (Hoffmann vd. 2019: e1318). Sınıflandırma problemine ilişkin görsele Şekil 2’de yer verilmiştir. Burada görüldüğü gibi sınıflandırma ile verilerin yapısal özellikleri göz önünde bulundurularak en tutarlı ayrım yapılmaya çalışılmaktadır.



Şekil 2: Destek Vektör Makinesi Sınıflandırma İşlemi

Kaynak: Yazar tarafında oluşturulmuştur.

Destek vektör makineleri tarihsel açıdan bir sınıflandırma algoritması olarak oluşturulmuş olmakla birlikte regresyon problemleri için de sıklıkla kullanılmaktadır. Algoritmanın amacı en basit şekilde; kendisine sunulan girdileri, bu girdilerin bulundukları uzay boyutundan daha yüksek bir uzay boyutuna taşıyarak optimal çözüm üretmek olarak ifade edilebilir. (İpek, 2022: 41-60).

2.2.4.1. Doğrusal Destek Vektör Regresyonu

Destek vektör regresyonu iki boyutlu uzayda doğrusal biçimde analizi mümkün olmayan veri setini daha yüksek boyutlu bir uzaya taşıyarak doğrusal biçimde analiz etmektedir. Bir hiperparametre olarak adlandırılan ε , modelde dışsal bir değişken olarak ele alınır, 9 ve 10 numaralı denklemlerde belirtilmekte olan kısıt fonksiyonlarının temel belirleyicisidir. Bu kısıt fonksiyonları altında 8 numaralı amaç fonksiyonu minimize edilerek optimal $f(x)$ fonksiyonuna ulaşılmaya çalışılır (Vapnik vd. 1996: 9), (Önay Koçoğlu, 2022).

$$y = f(x) = \langle w, x \rangle + b = \sum_{i=1}^n w_i x_i + b \quad y, b \in R \text{ ve } w, x \in R^n \quad (7)$$

$$\min \frac{1}{2} \|w\|^2 \text{ (amaç fonksiyonu)} \quad (8)$$


$$y_i - \langle w, x \rangle - b \leq \varepsilon \text{ (kısıt fonksiyonu)} \quad (9)$$

$$\langle w, x \rangle + b - y_i \leq \varepsilon \text{ (kısıt fonksiyonu)} \quad (10)$$

Optimal ε değerlerinin bulunması bir diğer ifade ile ε tüpünün bulunmasını ifade eder. $[-\varepsilon, +\varepsilon]$ olarak gösterilen ε tüpü, tahmin hatasını en düşük seviyede tutacak ve modelin genelleştirme kapasitesini en iyileyecek biçimde belirlenir. Bu tüp değerleri içerisinde kalan girdilere ait hata değerleri görmezden gelinerek modelde en fazla ε değeri kadar

hataya izin verilir. Bu görmezden gelme işlemi ε -duyarsız kayıp fonksiyonu ile ilişkilidir. 11 numaralı denklemde kayıp fonksiyonuna ilişkin matematiksel gösterime ve Şekil 3'te ise geometrik gösterime yer verilmiştir. 11 numaralı denklemde görüldüğü üzere veri, ε tüpü dışında kaldığında dikkate alınıyorken aksi durumda dikkate alınmamaktadır. Şekil 3'te görülen gösterimden de anlaşılacağı üzere bu fonksiyon konveks ve simetrik bir yapı sergilemekte olup optimizasyon probleminin tek bir çözüm değeri vermesine olanak sağlamaktadır. w parametresi, modele verilen girdilere bağımlı olarak belirlenir ve bu parametrenin amaç fonksiyonunda belirtildiği üzere büyüklüğü minimize edilmeye çalışılmaktadır. w parametresinin büyüklüğü bir düzenleme veya ayarlama terimi olarak görev yapmakla birlikte çözümün doğrusallığının belirlenmesinde önemli bir rolü vardır. Düzenleme ile ifade edilmek istenen tahmin doğrusunun veri setine uyum derecesidir. Bu bir başka açıdan sapma ve varyans arasındaki değiş tokuş ilişkisinin ifadesidir. Aşırı ayarlama sonucu tahmin doğrusu veri setine aşırı uyum gösterebilir, bu her ne kadar eğitim veri seti üzerinde düşük varyanslı bir öğrenim sürecine sebep olsa da test veri seti üzerinde yapılacak tahminler yüksek sapmalarla sonuçlanabilecektir, tam tersini düşünmek de mümkündür (Awad, 2015: 67-80).

$$L_{\varepsilon} = (y, (f(x, w))) = \begin{cases} 0, & |y - f(x, w)| \leq \varepsilon; \\ |y - f(x, w)| - \varepsilon & \text{diğer durumlarda.} \end{cases} \quad (11)$$



Şekil 3: Destek Vektör Regresyonu Kayıp Fonksiyonu

Kaynak: Bu şekil Smola vd. 2004 çalışmasından alınmıştır.

Destek vektör regresyonu için yukarıda yer verilen açıklamaların, uç değerleri göz ardı ediyor olması nedeniyle gerçek hayat problemlerinde sıklıkla yaşanan önemli bir sorunun

algoritma dışında bırakılması durumuyla karşılaşmaktadır. Bu durumun önüne geçmek amacıyla uç değerlerin de analize dahil edilmesi adına ξ_i ve ξ_i^* aylak değişkenler modele eklenmektedir. Bu değişkenlerin eklenmesi ile oluşan amaç ve kısıt fonksiyonları 13 ve 14 numaralı denklemlerde sırasıyla gösterilmiştir.

$$\min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^k (\xi_i + \xi_i^*) \quad (12)$$

$$y_i - \langle w, x \rangle - b \leq \varepsilon + \xi_i; \quad \xi_i \geq 0 \quad (13)$$

$$\langle w, x \rangle + b - y_i \leq \varepsilon + \xi_i^*; \quad \xi_i^* \geq 0 \quad (14)$$

12 numaralı denklemde görülmekte olan C katsayısı cezalandırma katsayısı olarak ifade edilmekte olup amaç fonksiyonunun çözümünde yer alan ve de sapma ve varyans arasındaki değiş tokuş ilişkisinin belirlenmesinde kullanılan yeni bir dışsal parametredir. C parametresi büyüdükçe modelin eğitim veri setine uyumu artar ancak test veri seti üzerindeki performansı tehlikeye girer, azalması durumunda ise eğitim veri setine yeterince uyum gösteremeyebilir. Bu sebeple algoritmanın optimal işlem kapasitesine ulaşabilmesi için C parametresinin araştırmacı tarafından iyi biçimde ayarlanması gerekecektir (Smola, Schölkopf, 2004: 199-222).

Bu aşamadan sonrası için 15 numaralı denklemde belirtilen eşitlik meydana gelmekte olup kuadratik optimizasyon problemi ile karşılaşmaktadır.

$$L(w, \xi_i, \xi_i^*, \alpha_i, \alpha_i^*, C, \beta_i, \beta_i^*) = \min \frac{1}{2} \|w\|^2 + C \sum_{i=1}^k (\xi_i + \xi_i^*) \quad (15)$$

$$\begin{aligned} & - \sum_{i=1}^k \alpha_i (\varepsilon + \xi_i - y_i + \langle w, x \rangle + b) \\ & - \sum_{i=1}^k \alpha_i^* (\varepsilon + \xi_i^* + y_i - \langle w, x \rangle - b) \\ & - \sum_{i=1}^k (\beta_i \xi_i + \beta_i^* \xi_i^*) \end{aligned}$$

Elde edilen 15 numaralı denklem üzerinden w, ξ_i, ξ_i^*, b elemanlarına bağlı olarak minimizasyon yapılırken $\alpha_i > 0, \alpha_i^* > 0, \beta_i > 0, \beta_i^* > 0 \quad i = 1, \dots, k$ Lagranj çarpanlarına bağlı olarak maksimizasyon yapılmaktadır.

$$\frac{dL(w, \xi_i, \xi_i^*, \alpha_i, \alpha_i^*, C, \beta_i, \beta_i^*)}{dw} = w - \sum_{i=1}^k (\alpha_i - \alpha_i^*) x_i = 0 \quad (16)$$

$$\frac{dL(w, \xi_i, \xi_i^*, \alpha_i, \alpha_i^*, C, \beta_i, \beta_i^*)}{db} = \sum_{i=1}^k (\alpha_i - \alpha_i^*) = 0 \quad (17)$$

$$\frac{dL(w, \xi_i, \xi_i^*, \alpha_i, \alpha_i^*, C, \beta_i, \beta_i^*)}{d\xi_i} = C - \beta_i - \alpha_i = 0 \quad (18)$$

$$\frac{dL(w, \xi_i, \xi_i^*, \alpha_i, \alpha_i^*, C, \beta_i, \beta_i^*)}{d\xi_i} = C - \beta_i^* - \alpha_i^* = 0 \quad (19)$$

15 numaralı Lagranj denkleminin ilgili parametrelere göre kısmı türevleri alındığında 16, 17, 18 ve 19 numaralı denklemler elde edilmektedir. Buradan hareketle 20 numaralı optimizasyon problemine gidilir, bu denklem ayrıca amaç fonksiyonunu da ifade eder. 21 numaralı eşitlik ile de kısıt fonksiyonu elde edilmektedir (Tolun, 2008).

$$\begin{aligned} \max L(\alpha, \alpha^*) = & \sum_{i=1}^k y_i(\alpha_i - \alpha_i^*) - \varepsilon \sum_{i=1}^k (\alpha_i + \alpha_i^*) \\ & - \frac{1}{2} \sum_{i,j=1}^k (\alpha_i - \alpha_i^*)(\alpha_j - \alpha_j^*) \langle x_i, x_j \rangle \end{aligned} \quad (20)$$

$$\sum_{i=1}^k (\alpha_i - \alpha_i^*) = 0; \quad \alpha_i, \alpha_i^* \in [0, C] \quad (21)$$

Son olarak w parametresi için Karush-Kuhn-Tucker koşulları sayesinde elde edilen 22 numaralı denklemde belirtilen eşitlik, 23 numaralı denklemde yerine konularak doğrusal regresyon modeli olan 24 numaralı denkleme ulaşılır (Mohandes, 2002: 335-345).

$$\begin{aligned} \frac{dL(w, \xi_i, \xi_i^*, \alpha_i, \alpha_i^*, C, \beta_i, \beta_i^*)}{dw} = & w - \sum_{i=1}^k (\alpha_i - \alpha_i^*) x_i = 0; \\ w = & \sum_{i=1}^k (\alpha_i - \alpha_i^*) x_i \end{aligned} \quad (22)$$

$$y = f(x) = \sum_{i=1}^n w_i x_i + b; \quad y, b \in R \text{ ve } w, x \in R^n \quad (23)$$

$$y = f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \langle x_i, x \rangle + b \quad (24)$$

Lagranj çarpanları olan α_i, α_i^* katsayıları kuadratik optimizasyon probleminin çözümünü sağlamaktadırlar. Tüm veri seti ε tüpü içerisinde kalırsa α_i, α_i^* 0 değerini alacaktır (Wu, 2004: 276-281).

2.2.4.2. Kernel Hilesi ve Doğrusal Olmayan Destek Vektör Regresyonu

Kernel hilesi, doğrusal olarak analiz edilmesi mümkün olmayan bir girdinin daha yüksek boyutlu bir uzaya bir diğer adı ile özellik uzayına haritalanarak, taşınarak doğrusal olarak analiz edilmesine imkân vermektedir. Haritalama fonksiyonu $\phi(x)$ ile sembolize edilmektedir. Doğrusal olmayan DVR 25 numaralı denklem ile gösterilmektedir (Smola, Schölkopf, 2004: 199-222).

$$y = f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) K(x_i, x) + b; \quad K(x_i, x) = \phi(x_i) \phi(x) \quad (25)$$

25 numaralı denklem ile doğrusal olmayan DVR ifade edilmiş olup K ile Kernel fonksiyonu sembolize edilmektedir. Bu fonksiyonların kullanılabilir olması pozitiflik, simetri ve süreklilik gibi Mercer koşullarının sağlanmasından geçmektedir.

Lineer Fonksiyon	$K(x_i, x_j) = x_i * x_j$
Polinomsal Fonksiyon	$K(x_i, x_j) = ((x_i * x_j) + r)^d$
Gaus Fonksiyon	$K(x_i, x_j) = \exp(-\gamma \ x_i * x_j\ ^2)$

Tablo 2: Kernel Fonksiyonları

Kaynak: G. Santamaría-Bonfil vd.

Uygulamada çeşitli Kernel fonksiyonlarına rastlanmakta olup bunlar Tablo 2 ile gösterilmiştir (Santamaría-Bonfil vd., 2015: 111-133), (Demirezen, Çetin, 2021: 1-15).

2.2.5. Otoregresif Hareketli Ortalama (ARMA)

Temelleri 1970’li yıllara dayanan otoregresif hareketli ortalama bir diğer adı ile Box-Jenkins yöntemi günümüzde de zaman serilerinin tahmininde sıklıkla yer almaktadır. Bu yöntem herhangi bir iktisadi kuram tarafından şekillenmemiş olup veri odaklı bir tahmin aracı olarak kullanılagelmektedir. Bir serinin kendi geçmiş değerleri ve yine bu serinin hata terimlerinden oluşan modelde, tahmin için veriyi etkileyebilecek iç ve dış unsurlar bulunmaktadır (Box vd., 2015).

$$(Y_t - \delta) = \alpha_1(Y_{t-1} - \delta) + e_t \quad (26)$$

26 numaralı denklem, AR(1) yani tek gecikmesi modele eklenmiş bir otoregresif yapıyı ifade etmektedir. Bu yapıda δ , Y_t ’nin ortalamasını, Y_{t-1} bir dönem gecikmeyi, e_t ise ortalaması sıfır ve varyansı σ^2 sabit olan hata terimini (beyaz gürültü) sembolize etmektedir. Bu denklemden yola çıkarak t dönemi için yapılacak bir değer tahmininin, kendi geçmiş değerinin α_1 kadar bir oranı ile t dönemindeki rassal bir etkinin toplamından ibaret olduğu anlaşılmaktadır. Model daha yüksek dereceden kurgulanmak istenirse 27 numaralı denklemdeki gösterime ulaşılmaktadır.

$$(Y_t - \delta) = \alpha_1(Y_{t-1} - \delta) + \alpha_2(Y_{t-2} - \delta) + \dots + \alpha_p(Y_{t-p} - \delta) + e_t \quad (27)$$

27 numaralı denklem AR(p) olarak ifade edilir ve t dönemi için yapılacak tahminin, ilgili zaman serisinin p kadar kendi geçmiş değerleri ile kendini açıklayabilme durumunu ifade eder ve en küçük kareler yöntemi ile çözümlenebilmektedir.

$$Y_t = \mu + \beta_0 e_t + \beta_1 e_{t-1} \quad (28)$$

28 numaralı denklem bir hareketli ortalama gösterimidir. MA(1) olarak adlandırılan bu süreçte yer alan μ sabit terimi, e_t beyaz gürültüyü ve e_{t-1} ise onun bir dönem gecikmeli değerlerini sembolize etmektedir. 29 numaralı denklem ile daha yüksek boyutlu bir gösterime ulaşmakla birlikte bu gösterim MA(q) olarak adlandırılmaktadır ve çözümü için en çok olabilirlik yöntemi kullanılmaktadır (Gujarati, 2022). Otoregresif yapı kurgusu serinin geçmiş değerleri ile kendini açıklayabilmesini ifade ederken hareketli ortalama, serinin dışsal etkiler üzerinden açıklanmasını temsil eder.

$$Y_t = \mu + \beta_0 e_t + \beta_1 e_{t-1} + \beta_2 e_{t-2} + \dots + \beta_q e_{t-q} \quad (29)$$

Otoregresif yapı ile hareketli ortalama yapısının bir arada gösterildiği 30 numaralı denklem otoregresif hareketli ortalama (ARMA) yapısını ifade etmektedir.

$$Y_t = \theta + \sum_{i=1}^p \alpha_i Y_{t-i} + \sum_{i=0}^q \beta_i e_{t-i} \quad (30)$$

Bir zaman serisi yalnızca otoregresif biçimde veya yalnızca hareketli ortalama biçimde ve son olarak otoregresif hareketli ortalama biçiminde kurgulanabilir. 30 numaralı denklemde θ sabit katsayısını, α ve β sırasıyla AR ve MA yapılarına ait katsayıları sembolize etmektedir. Model kurgusunun belirlenmesinde Box-Jenkins yöntemi olarak bilinen sıralı işlemler uygulanmaktadır. Bu işlem sırası Şekil 4 ile gösterilmiştir.



Şekil 4: Box-Jenkins Metodolojisi

Kaynak: Yazar tarafından oluşturulmuştur.

2.2.6. Hibrit Yöntem

Bu yöntemde bir veri seti doğrusal ve doğrusal olmayan olmak üzere iki ayrı durumda ele alınmaktadır. Öncelikle hangi kısmın tahmin edildiği göz önünde bulundurularak elde edilen tahmin değerleri tüm veri setinden çıkarılarak kalan kısma ait veri seti meydana getirilmektedir. 31 numaralı eşitlikte $V_t^{toplaml}$, içerisinde doğrusal ve doğrusal olmayan yapıları barındırma ihtimali bulunan bir zaman serisini ifade etmektedir. Her iki yapısal durumu haiz olduğu varsayımı altında, bu veri seti doğrusal ve doğrusal olmayan biçimlerin toplamı olarak düşünülebilmektedir.

$$V_t^{toplaml} = V_t^{doğrusal\ bileşenler} + V_t^{doğrusal\ olmayan\ bileşenler} \quad (31)$$

Bu çalışmada serinin uzun dönem bilgisini korumak amacıyla fark işlemi almadan serinin öncelikle doğrusal olmayan kısmının tahmin edilmesi yolu izlenmiştir. Destek vektör regresyonunun doğrusal olmayan çözümleme yapısı kullanılarak $V_t^{toplaml}$ serisi üzerinden $\hat{V}_t^{DVR}$ serisine, bir diğer ifade ile doğrusal olmayan tahmin değerlerine ulaşılır. Tahmin edilen doğrusal olmayan kısım, gerçek veri setinden çıkarılarak bir kalıntı serisi elde edilir ve bu veri seti, analizin doğrusal kısmının analizi için kullanılacak veri setini ifade eder. Şayet DVR ile analize başlanmasa idi serilerin seviyesinde durağan olmayan yapılarının ARMA için durağanlaştırılması yani farklarının alınması gerekirdi. Uzun dönem bilgisinin kaybı anlamına gelen fark işleminden bu yöntemle kaçınılabilmektedir.

$$V_t^{toplaml} - \hat{V}_t^{DVR} = e_t^{DVR} \quad (32)$$

e_t^{DVR} destek vektör regresyonu ile yapılan çözümlemenden elde edilen kalıntılardır ve ARMA yapısı için kullanılacak doğrusal veri setini ifade eder. Bu kalıntılar kullanılarak ulaşılacak olan tahmin değerleri hibrit modelin $\hat{V}_t^{ARMA}$ kısmını oluşturacaktır.

$$e_t^{DVR} = f(e_{t-1}^{DVR}, e_{t-2}^{DVR}, \dots, e_{t-p}^{DVR}, \varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}) + u_t \quad (33)$$

33 numaralı eşitlik ile ifade edilen ARMA sürecinin işletilmesi sonucunda elde edilecek olan tahmin değerleri ile daha önceden DVR ile elde edilen tahmin değerleri toplanarak hibrit model tahmin değerlerine ulaşılır. 34 numaralı eşitlik ile hibrit tahmin değerleri gösterilmektedir (Zhang, 2003: 159-175).

$$\hat{V}_t^{hibrit} = \hat{V}_t^{DVR} + \hat{V}_t^{ARMA} \quad (34)$$

Böylelikle veri setinin tahmini aşamasında, doğrusal ve doğrusal olmayan yapılara karşı daha fazla hassasiyet taşıyan iki farklı model kullanarak elde edilen sonuç daha güçlü bir bulguya ulaştırılmaya çalışılmaktadır (Kumar, Thenmozhi, 2014: 284-308).

3. BÖLÜM: BULGULAR

Tablo 3’de görüleceği üzere FADF sonuçlarına göre serilerin hiçbirinin seviyesinde durağan olmadığı anlaşılmaktadır. Her ne kadar elde edilen bu sonuçlar serilerin seviye halleri hakkında bilgi verse de F hesap değerlerinin kritik tablo değerlerini aşamıyor olması nedeni ile seriler ADF yöntemi ile tekrardan incelemeye alınmıştır.

Değişken	Model	Gecikme	Frekans	t-ist.	F-ist.
Toplam Emisyon	Sabitli	8	1	-2,6570	0,3188
Toplam Emisyon	Sabit ve Trend	0	3	-7,9999	3,2288
CO2	Sabitli	7	2	-2,7480	0,3263
CO2	Sabit ve Trend	7	2	-3,2473	4,7425
N2O	Sabit	8	4	-2,8908	0,7133
N2O	Sabit ve Trend	8	1	-4,2059	5,8429
F	Sabit	8	3	-2,8738	3,3394
F	Sabit ve Trend	8	3	-2,4163	5,2901

Analiz Gaus 16 yazılım programı aracılığı ile yapılmıştır. Kritik tablo değerleri için (Enders ve Lee; 2012)

Tablo 3: Fourier Augmented Dickey-Fuller Test Sonuçları

Kaynak: Yazar tarafından oluşturulmuştur.

Tablo 4’te yer verilen sonuçlar FADF birim kök testi sonuçlarını doğrular niteliktedir. Sonuç olarak çalışmada kullanılan serilerin seviyesinde durağan olmadığı büyük oranda anlaşılmıştır. Böylece serilerin doğrusal bir yapı sergilemedikleri görsel analizle, durağan bir yapı sergilemedikleri ise birim kök analiz bulguları ile desteklenmiştir. Buradan hareketle serilerin tahmin edilmesine öncelikle destek vektör regresyonu ile başlanmıştır.

Değişken	Model	Gecikme	t-ist
TSG	Sabitli ve Trendli	0	-2,201855
CO2	Sabitli ve Trendli	0	-2,737184
N2O	Sabitli ve Trendli	4	0,050512
F	Sabitli ve Trendli	0	-1,197486

Analiz Eviews 9 yazılım programı aracılığı ile yapılmıştır. Uygun model seçimi Φ testleri aracılığı tespit edilmiştir.

Tablo 4: Augmented Dickey-Fuller Birim Kök Test Sonuçları

Kaynak: Yazar tarafından oluşturulmuştur.

Serilerin büyük oranda doğrusal ve durağan olmayan bir yapı içeriyor olmalarından dolayı öncelikli olarak uygulanan destek vektör regresyonlarına ilişkin hiperparametreler, Tablo 5 ile gösterilmiştir. Uygun parametreler ızgara tarama (GridSearch) yöntemi ile bulunmuştur. Bu yöntem her bir parametre için verilen sayısal aralık ve artış hızı

girdilerini dikkate alarak tüm parametre değerleri ile modeli kurgular ve optimal sonuca sahip parametre kümesini döndürür. Parametre sayısı ve kontrol edilecek değer sayısındaki artış bu yöntemin kullanılmasını zor ve maliyetli hale getirmektedir (Goodfellow, 2016).

Seri	C	ϵ	Gamma	Gecikme Sayısı	Kernel Fonksiyonu
TSG	300	0.05	0.001	4	Radyal Temelli Fonksiyon
CO2	150	0.1	0.005	1	Radyal Temelli Fonksiyon
N2O	300	0.01	0.005	5	Radyal Temelli Fonksiyon
F	450	0.05	0.01	3	Radyal Temelli Fonksiyon

Analiz Python yazılım kütüphanelerinden Scikit-Learn kullanılarak yapılmıştır.

Tablo 5: Kurgulanan Modellere Ait Hiperparametre Değerleri

Kaynak: Yazar tarafından oluşturulmuştur.

32 gözleme sahip olan örneklem yüksek boyutlu bir yapıya sahip olmaması sebebi ile destek vektör regresyonu kurgusunda otoregresif yapı en fazla 6 gecikmeye kadar oluşturulmuştur. En uygun gecikme uzunluğuna sahip model için test verisi üzerindeki performans ölçümleri dikkate alınmıştır. Toplam sera gazları için 4, CO2 için 1, N2O serisi için 5 ve F gazlar için 3 gecikmeye sahip kurguların en iyi performans değerlerine sahip olduğu görülmüştür.

Çalışma boyunca dört farklı performans değerlendirme kriteri kullanılmıştır. Bunlar mutlak ortalama hatalar, mutlak hata ortalamasının yüzdesi, ortalama hata kareler ve ortalama hata karelerinin kareköküdür. Bahsedilen bu kriterlerin formülasyonlarına Tablo 6'da yer verilmiştir.

Mutlak Ortalama Hata (Mean Absolute Error)	$\frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $
Mutlak Hata Ortalamasının Yüzdesi (Mean Absolute Percentage Error)	$\frac{1}{n} \sum_{i=1}^n \frac{ y_i - \hat{y}_i }{\max(\epsilon, y_i)}$
Ortalama Hata Kareleri (Mean Squared Error)	$\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2$
Ortalama Hata Karelerinin Karekökü (Root Mean Squared Error)	$\sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2}$

Tablo 6: Performans Kriterleri Tablosu

Kaynak: Yazar tarafından oluşturulmuştur.

En iyi performans ölçümlerine sahip otoregresif yapılar belirlendikten sonra ilgili seriler, belirlenen bu optimal gecikme uzunluğu kullanılarak, model eğitim ve test aşamasına geçilmiştir. Tüm seriler %20 test ve %80 eğitim verisi olarak ayrılmış ve analiz gerçekleştirilmiştir. Tablo 7 destek vektör regresyonu kurgularına ait performans ölçüm değerlerini göstermektedir.

Eğitim Veri Setine Ait Değerler				
Seri	MAE	MAPE	MSE	RMSE
TSG	0.0926	0.2925	0.0150	0.1226
CO2	0.0997	0.3497	0.0144	0.1203
F	0.0568	0.3406	0.01454	0.1205
N2O	0.1039	0.2242	0.0283	0.1685
Test Veri Setine Ait Değerler				
Seri	MAE	MAPE	MSE	RMSE
TSG	0.1531	0.1053	0.0290	0.1703
CO2	0.1919	0.1291	0.0471	0.2171
F	0.3170	0.1875	0.1571	0.3963
N2O	0.1896	0.1064	0.0576	0.2401

Analiz Python yazılım kütüphanelerinden Scikit-Learn kullanılarak yapılmıştır.

Tablo 7: Destek Vektör Regresyonu Performans Ölçüm Değerleri

Kaynak: Yazar tarafından oluşturulmuştur.

Destek vektör regresyonu ile tahmin edilen seriler ile gerçek değerlerin farkını ifade eden artıklar kullanılarak ARMA yapısı kurgulanmıştır. Kurgulanan bu modeller için uygun gecikme uzunluğu, mümkün modeller içerisinde en düşük Akaike (AIC) değerine sahip olana göre belirlenmiştir. Kurgulanan modellere ait bilgiler Tablo 8 ile gösterilmektedir.

Seriler	Model	Otokorelasyon	ARCH Test
TSG	AR(1) [0,0000]	-	[0,6352]
	AR(2) [0,0238]		
	MA(1) [0,0185]		
CO2	AR(2) [0,0436]	-	[0,4323]
F	AR(1) [0,0000]	-	[0,1175]
N2O	C [0,9866]	-	[0,6058]
	AR(1) [0,0094] MA(1) [0,9996]		
	AR(2) [0,0000] MA(2) [0,9998]		

Analizler Eviews 9 yazılım programı kullanılarak yapılmıştır.

Tablo 8: AR, MA, ARMA Modelleri

Kaynak: Yazar tarafından oluşturulmuştur.

Modeller otokorelasyon ve değişen varyans olmak üzere iki tanısal teste tabi tutulmuştur. Elde edilen sonuçlar modellerin tanısal açıdan bir sorun içermediğini göstermiştir.

Otokorelasyon testi modele ait kolegram görüntüsü üzerinden yapılmıştır. Otokorelasyon ve kısmi otokorelasyon katsayılarına ait olasılık değerlerinin tamamının yüzde beş hata payından yüksek olduğu görülmüştür. Değişen varyans için ise modelin kalıntılarının karesinin geçmiş değerleri ile ilişkisini kurgulayan ARCH testi bir gecikme için uygulanmıştır. Elde edilen olasılık değerleri varyansın zamandan bağımsız olduğunu işaret etmiştir. Dolayısıyla ARMA tahmin değerlerinin hibrit veri setinin oluşturulmasında elverişli olduğu sonucuna ulaşılmıştır.

Serilerin seviye hallerinden elde edilen destek vektör regresyonu tahmin değerleri ile bu regresyonların kalıntıları kullanarak elde edilen ARMA tahmin değerleri toplanarak hibrit veri seti oluşturulmuştur. Oluşturulan hibrit tahmin değerleriyle destek vektör regresyonu tahmin değerleri Tablo 6 ile ifade edilmiş olunan performans ölçüm kriterleri vasıtasıyla karşılaştırılmıştır. Elde edilen sonuçlar Tablo 9 ile gösterilmektedir.


Eğitim Veri Setine İlişkin Ölçüm Değerleri				
Değişken	RMSE	MSE	MAPE	MAE
TSG- DVR	0.1226	0.0150	0.2925	0.0926
TSG- Hibrit	0.1100	0.0121	0.1627	0.0845
CO2- DVR	0.1203	0.0144	0.3497	0.0997
CO2- Hibrit	0.1205	0.0145	0.3406	0.0941
F- DVR	0.0902	0.0081	0.2005	0.0568
F- Hibrit	0.1177	0.0138	0.2065	0.0651
N2O- DVR	0.1685	0.0283	0.2242	0.1039
N2O- Hibrit	0.1307	0.0170	0.3199	0.0929
Test Veri Setine İlişkin Ölçüm Değerleri				
Değişken	RMSE	MSE	MAPE	MAE
TSG- DVR	0.1703	0.0290	0.1053	0.1531
TSG- Hibrit	0.1326	0.0176	0.0840	0.1223
CO2- DVR	0.2171	0.0471	0.1291	0.1919
CO2-Hibrit	0.1867	0.0348	0.1122	0.1662
F- DVR	0.3963	0.1571	0.1875	0.3170
F- Hibrit	0.2463	0.0607	0.1483	0.2206
N2O- DVR	0.2401	0.0576	0.1064	0.1896
N2O- Hibrit	0.1195	0.0142	0.0472	0.0916

Tablo 9: Hibrit ve DVR Tahmin Değerlerinin Karşılaştırılması

Kaynak: Yazar tarafından oluşturulmuştur.


Sonuçlar incelediğinde genel itibarıyla hibrit modelin daha iyi değerlere sahip olduğu görülmektedir. Her ne kadar DVR'nin CO2 ve F gazlar serileri üzerinde eğitim veri seti özelinde daha düşük hata değerleri döndürdüğü görülse de kalan diğer tüm alanlarda hibrit model sonuçlarının üstün bir pozisyonda olduğu anlaşılmaktadır. Grafik 5 ve 6 ile

sırasıyla eğitim ve test verileri için yapılan performans ölçüm kriterlerinin karşılaştırmasına yer verilmiştir.



Grafik 5: Eğitim Verilerine Ait RMSE Karşılaştırması

Kaynak: Yazar tarafından oluşturulmuştur.




Grafik 6: Test Verilerine Ait RMSE Karşılaştırması

Kaynak: Yazar tarafından oluşturulmuştur.


Hibrit modelin test verisi üzerindeki başarısı özellikle doğrusal olmayan yapının daha belirgin olduğu F gazları ve N2O serileri açısından daha belirgin biçimde göze çarpmaktadır. F gazları özelinde yapılacak bir incelemede hibrit modelin DVR'ye göre daha yüksek bir eğitim hatasına sahip olduğu görülmektedir. Ancak bu durum test verisi üzerinde hibrit modelin daha düşük hata değerine sahip olmasına neden olmuştur benzer durum CO2 serisi üzerinde de en azından rakamsal açıdan karşılık bulmaktadır. Bir diğer

ifade ile hibrit model DVR'nin aşırı uyum probleminin çözümüne de katkıda bulunmuştur. Toplam sera gazları ve N₂O serileri açısından ise hibrit model, eğitim verisi üzerinde daha uyumlu bir öğrenme süreci meydana getirmiştir. Burada ise DVR'nin eğitim verisi üzerindeki eksik öğrenme problemi giderilmiş olup test verisi üzerinde daha etkin sonuçlar alınmıştır. Özetle eğitim sürecinde gerek eksik öğrenme gerekse aşırı öğrenme-uyum süreçlerini dengeler bir görev üstlendiği anlaşılan hibrit modelin, daha önce göremediği veri setleri üzerinde yani test verileri üzerinde daha iyi sonuçlar üretebildiği gözlenmiştir. Tahmin edilen serilerin çizgisel biçimde gösterimlerine Grafik 7, 8, 9 ve 10 ile yer verilmiştir.




Grafik 7: Toplam Sera Gazı Serisi Tahmin Değerleri

Kaynak: Yazar tarafından oluşturulmuştur.




Grafik 8: CO2 Gazı Serisi Tahmin Değerleri

Kaynak: Yazar tarafından oluşturulmuştur.



Grafik 9: N2O Gazı Serisi Tahmin Değerleri

Kaynak: Yazar tarafından oluşturulmuştur.



Grafik 10: F Gazı Serisi Tahmin Değerleri

Kaynak: Yazar tarafından oluşturulmuştur.

Son olarak toplam sera gazı emisyonu için 2022-2030 yıllarına ait ileri dönük tahminde bulunulmuştur. Diğer seriler için ise 2025 yılına kadar tahminde bulunulmuştur. Tahmin değerlerini 7, 8, 9 ve 10 numaralı grafikler üzerinde görmek mümkündür.

SONUÇ

Veri, insan algısının oluşumunda yer alan temel unsurlardan biridir. Veri günümüzde de aynı etkiye sahip olmakla birlikte sayısal açıdan ulaşmış olduğu devasa boyutlarla geçmişe nazaran farklılık göstermektedir. Bu büyük ölçekli veri, günümüze kadar gelmiş ve gelişimi devam eden bilgi işleme tekniklerinin hem bir nedeni hem de bir sonucu olarak karşımıza çıkmaktadır. İnsanlık tarihi boyunca aklın herhangi bir sahasında, verinin mümkün olabilecek en doğru biçimde işlenmesi ve dolayısıyla en muhtemel bilginin elde edilmesi ilerlemenin daimî kaynağı olmuştur. Dönemin özel şartları ne olursa olsun içtimai veya diğer alanlarda ortaya çıkan her problemin çözümü, problemi çözüme kavuşturacak verilerin doğru analizi ile mümkündür. Günümüz problemlerinden biri olan enerji ve iklim sorunu için de eldeki verilerin en doğru biçimde analiz edilmesi ve en muhtemel bilgiye ulaşılması gerekmektedir. Bu sebeple yalnızca model kurgusu değil verinin yapısal durumunun tespiti de büyük önem arz etmektedir.

Analize konu olan sera gazı verileri, yapısal durumları hakkında bilgi edinilmek üzere grafiksel, matematiksel ve ekonometrik yöntemler aracılığıyla analiz edilmiştir. Serilerin doğrusal bir yapı izlemedikleri ve birim köke sahip oldukları bir diğer ifade ile durağan olmadıkları görülmüştür. Durağan yapıya sahip olmayan bu seriler modellenme aşamasında, fark alma işleminin uygulanmaması için öncelikle destek vektör regresyonu ile modellenmiştir. Elde edilen kalıntı değerleri kullanılarak ARMA süreci kurgulanmıştır ve hibrit modele ait veri seti oluşturulmuştur. DVR ve hibrit model karşılaştırması sonucu hibrit modelin daha doğru sonuçlar ortaya koyduğu görülmüştür. DVR'nin tek başına yeterli olmadığı, serideki doğrusallığın ölçümünde eksik kaldığı anlaşılmıştır. Karmaşık yapılar sergileyen serilerin içindeki farklı düzenlere karşı özel hassasiyet taşıyan modellerin bir arada kullanılması sonucunda varyans sapma takasında daha optimal bir noktaya varılarak test verisi üzerinde daha doğru sonuçlar elde edilmiştir.

2022-2025 yıllarına ait ileri dönük tahminlerde toplam sera gazı ve F gazı serilerinde artış, CO₂ ve N₂O gazı serilerinde azalış hesaplanmıştır. 2021 yılı itibarıyla 564,38 milyon ton olan toplam sera gazı salınımı, 2025 yılı için 611,59 milyon ton ve 2030 yılı için 683 milyon ton olarak bulunmuştur. Paris Antlaşması'na göre yüzde 21 artıştan azaltım niyetinde bulunan ve daha sonra bu hedefini yüzde 41 olarak güncelleyen Türkiye, normal şartlar dahilinde 2030 yılında 1.175 milyon ton salınımına ulaşacağı öngörüsüne dayanarak hedeflerini sunmuştur. Buna göre 2030 yılı için yaklaşık 833 milyon ton salınımla sınırlı

kalması gereken artıştan azaltım hedefinin tutturulabilmesi edinilen bulgular ışığında mümkün görünmektedir. 1990-2021 dönemine ait sera gazı salınım değerlerinin yıllık bazda artışları dikkate alındığında elde edilecek ortalama artış hızı yüzde 3 düzeyindedir. Dolayısıyla ortalama yüzde 3 artış hızının gelecek dönemlerde devam edeceği varsayımı altında, 2030 yılı için 691 milyon ton salınımına ulaşılması ihtimali bulunmaktadır. Bu durumda da yine Türkiye'nin hedeflerine varması mümkün görünmektedir. Diğer yandan covid-19 salgını esnasında yaşanan sokağa çıkma yasakları ve dolayısıyla sosyal alandaki faaliyetlerin azaltılması veya durdurulması gibi etkiler göz önünde bulundurulduğunda serilerin aşağı yönlü bir trend gösterdiği, bunun da gelecek dönem tahminlerini etkilediği düşünülebilir. 2019 yılında hanehalkı tüketim harcamalarının ortalama zincirlenmiş hacim endeksi (2009 baz yıl kabul edilmektedir) 170.6 iken sırasıyla 2020, 2021, 2022, 2023 yılları için bu değerlerin 167.3, 197.6, 239.3, 266.7 olduğu, 2009-2023 ortalamasının ise 161.1 olduğu görülmektedir. Dolayısıyla Pandemi döneminin sona ermesiyle birlikte ekonomik alanda ötelenen talebin yaşadığı basıncın etkisiyle çok güçlü bir biçimde ortaya çıktığı anlaşılmaktadır. Özellikle 2021 yılı ve sonrası dönemde ekonomik aktivitenin aşırı ısındırılması da hesaba katıldığında karbon salınımında tahmin değerlerinin üzerine çıkılması ihtimali daha da artmaktadır.

Son dönemlerde yaşanan küresel olumsuzluklar sebebi ile karmaşıklığı artan dünya düzeninde geleceği tahmin etmenin güç bir hal aldığı açıktır. Şokların etkisinin sık ve yoğun olduğu bu süreçlerde doğru tahminler üretebilmek her ne kadar güç olsa da rasyonel politikaların oluşturulabilmesi için bu analizlerin yapılması zaruridir. Bu sebeple karmaşıklığın daha doğru çözümü için veri ön işleme aşamalarının etkin bir biçimde kullanılması ve bir diğer ifade ile verinin röntgenin çekilmesinin, model kurgulama aşaması kadar önemli olduğu dikkatten kaçırılmamalıdır.

KAYNAKÇA

- Akyol, M., & Uçar, E. (2021). Carbon footprint forecasting using time series data mining methods: the case of Turkey. *Environmental Science and Pollution Research*, 28, 38552-38562.
- Awad, M., Khanna, R., Awad, M., & Khanna, R. (2015). Support vector regression. *Efficient learning machines: Theories, concepts, and applications for engineers and system designers*, 67-80.
- Bakay, M. S., & Ağbulut, Ü. (2021). Electricity production based forecasting of greenhouse gas emissions in Turkey with deep learning, support vector machine and artificial neural network algorithms. *Journal of Cleaner Production*, 285, 125324.
- Boğar, E., & Boğar, Z. Ö. (2017). Türkiye'nin sektörel CO₂ gazı salınımlarının yapay sinir ağları ile tahmini. *Akademia Disiplinlerarası Bilimsel Araştırmalar Dergisi*, 3(2), 15-27.
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- C. Hamzacebi & I. Karakurt (2015) Forecasting the Energy-related CO₂ Emissions of Turkey Using a Grey Prediction Model, *Energy Sources, Part A: Recovery, Utilization, and Environmental Effects*, 37:9, 1023-1031, DOI: 10.1080/15567036.2014.978086.
- Çağlayan Akay, E., (2020). *Ekonometride Büyük Veri ve Makine Öğrenmesi: Temel Kavramlar*. İstanbul: Der Yayınları.
- Çeşmeli, M. Ş., & Pençe, İ. (2020). Makine Öğrenimi Yöntemleri ile Türkiye için Sera Gazı Emisyonu Tahmini. *Academic Platform-Journal of Engineering and Science*, 8(2), 332-348.
- Demirezen, S., & Çetin, M. (2021). RASSAL ORMAN REGRESYONU VE DESTEK VEKTÖR REGRESYONU İLE PİYASA TAKAS FİYATININ TAHMİNİ. *Nicel Bilimler Dergisi*, 3(1), 1-15.
- Dickey, D. A., & Fuller, W. A. (1981). Likelihood ratio statistics for autoregressive time series with a unit root. *Econometrica: journal of the Econometric Society*, 1057-1072.
- Dickey, D. A., & Fuller, W. A. (1979). Distribution of the estimators for autoregressive time series with a unit root. *Journal of the American statistical association*, 74(366a), 427-431.
- Drucker, H., Burges, C. J., Kaufman, L., Smola, A., & Vapnik, V. (1996). Support vector regression machines. *Advances in neural information processing systems*, 9.

- Enders, W., & Lee, J. (2012). The flexible Fourier form and Dickey–Fuller type unit root tests. *Economics Letters*, 117(1), 196-199.
- Geevaretnam, J. L., Zainuddin, N. M. M., Kamaruddin, N., Rusli, H., Maarop, N., & Hassan, W. A. W. (2022). Predicting the carbon dioxide emissions using machine learning. *International Journal of Innovative Computing*, 12(2), 17-23.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT press.
- Granger, C. W., & Newbold, P. (1974). Spurious regressions in econometrics. *Journal of econometrics*, 2(2), 111-120.
- Gujarati, D. N. (2022). *Basic econometrics*. Prentice Hall.
- Hoffmann, F., Bertram, T., Mikut, R., Reischl, M., & Nelles, O. (2019). Benchmarking in classification and regression. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(5), e1318.
- İpek Ö., (2022)İktisat ve Finansta Makine Öğrenmesi. Gazi Kitapevi.
- 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), 6336.
- Karakaya, E. (2016). Paris iklim anlaşması: içeriği ve Türkiye üzerine bir değerlendirme. *Adnan Menderes Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 3(1), 1-12.
- Kayakuş, M., Terzioğlu, M., Erdoğan, D., Zetter, S. A., Kabas, O., & Moiceanu, G. (2023). European Union 2030 carbon emission target: The case of Turkey. *Sustainability*, 15(17), 13025.
- Köne, A. Ç., & Büke, T. (2010). Forecasting of CO2 emissions from fuel combustion using trend analysis. *Renewable and Sustainable Energy Reviews*, 14(9), 2906-2915.
- Kumar, M., & Thenmozhi, M. (2014). Forecasting stock index returns using ARIMA-SVM, ARIMA-ANN, and ARIMA-random forest hybrid models. *International Journal of Banking, Accounting and Finance*, 5(3), 284-308.
- Mason, K., Duggan, J., & Howley, E. (2018). Forecasting energy demand, wind generation and carbon dioxide emissions in Ireland using evolutionary neural networks. *Energy*, 155, 705-720.
- Meng, Y., & Noman, H. (2022). Predicting CO2 Emission Footprint Using AI through Machine Learning. *Atmosphere*, 13(11), 1871.
- Mohandes, M. (2002), Support vector machines for short-term electrical load forecasting. *Int. J. Energy Res.*, 26: 335-345.
- Namboori, S. (2020). Forecasting carbon dioxide emissions in the United States using machine learning (Doctoral dissertation, Dublin, National College of Ireland).

- Önay Koçoğlu, F., (2022). Denetimli Makine Öğrenmesi Algoritmaları: Destek Vektör Makineleri-Regresyon. Nobel Yayın.
- Öztürk, M., & Öztürk, A. (2019). BMİDÇS'den Paris Anlaşması'na: Birleşmiş Milletler'in İklim Değişikliğiyle Mücadele Çabaları. Ömer Halisdemir Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi, 12(4), 527-541.
- Pabuçcu, H., & Bayramoğlu, T. (2016). Yapay sinir ağı ile CO2 emisyonu tahmini: Türkiye örneği. *Gazi Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 18(3), 762-778.
- Santamaría-Bonfil, G., Frausto-Solís, J., & Vázquez-Rodarte, I. (2015). Volatility forecasting using support vector regression and a hybrid genetic algorithm. *Computational Economics*, 45, 111-133.
- Smola, A. J., & Schölkopf, B. (2004). A tutorial on support vector regression. *Statistics and computing*, 14, 199-222.
- Sözen, A., Gülseven, Z., & Arcaklioğlu, E. (2007). Forecasting based on sectoral energy consumption of GHGs in Turkey and mitigation policies. *Energy policy*, 35(12), 6491-6505.
- Sözen A., Gülseven Z. & Arcaklioğlu E., (2009) Estimation of GHG Emissions in Turkey Using Energy and Economic Indicators, *Energy Sources, Part A*, 31:13, 1141-1159.
- Türkeş, M. (2000). Hava, İklim, Şiddetli Hava Olayları ve Küresel Isınma. TC Başbakanlık Devlet Meteoroloji İşleri Genel Müdürlüğü, 187, 205.
- Türkeş, M. (2006). Küresel iklimin geleceği ve Kyoto Protokolü. *Jeopolitik*, 29, 99-107.
- Türkeş, M. (2008). Küresel iklim değişikliği nedir? Temel kavramlar, nedenleri, gözlenen ve öngörülen değişiklikler. *İklim Değişikliği Ve Çevre*, 1(1), 26-37.
- Tolun, S. (2008). Destek vektör makineleri: Banka başarısızlığının tahmini üzerine bir uygulama. *İktisadî Araştırmalar Vakfı*.
- Wu, C. H., Ho, J. M., & Lee, D. T. (2004). Travel-time prediction with support vector regression. *IEEE transactions on intelligent transportation systems*, 5(4), 276-281.
- Zhang, G. P. (2003). Time Series Forecasting Using A Hybrid ARIMA and Neural Network Model. *Neurocomputing*, 50, 159-175.
- <https://www.mfa.gov.tr/bm-iklim-degisikligi-cerceve-sozlesmesi.tr.mfa>. E.T. 15/06/2024
- T.C. Ministry of Foreign Affairs/Kyoto Protocol, <https://www.mfa.gov.tr/kyoto-protokolu.tr.mfa>. E.T. 15/06/2024
- <https://www.mfa.gov.tr/paris-anlasmasi.tr.mfa>. E.T. 15/06/2024

ÖZ GEÇMİŞ

Ad Soyad: Mustafa KARAKUZU	
Eğitim Bilgileri	
Lisans	
Üniversite	Gazi Üniversitesi
Fakülte	İktisadi ve İdari Bilimler Fakültesi
Bölümü	İktisat
Makale ve Bildiriler	
1. Karakuzu, M., & Yıldız, H. (2023). Türkiye’de İktisadi Hoşnutsuzluğun Kayıt Dışı İstihdam Üzerindeki Etkisi: ARDL Sınır Testi Yaklaşımı. <i>JOEEP: Journal of Emerging Economies and Policy</i> , 8(2), 168-178.	