

OECD EKONOMİLERİNDE YEŐİL TEKNOLOJİ YAYILIMININ MAKİNE ÖĞRENMESİ ANALİZİYLE ÖNGÖRÜLMESİ

Makine Öğrenimi Analizi Yoluyla OECD Ekonomilerinde Yeşil Teknoloji Yayılımının Tahmini

Büşra AĞAN* 

Özet

Sürdürülebilir kalkınmaya doğru hızlanan küresel deęişim, özellikle OECD ekonomilerinde yeşil teknolojilerin yayılmasını kritik bir odak alanı haline getirmiştir. Bu çalışma, OECD ülkeleri arasında yeşil teknolojinin gelecekteki yayılımını keşfetmek için bir makine öğrenimi yaklaşımı kullanmayı amaçlamaktadır. Farklı ülkeler arasında yeşil teknoloji yayılımının (GTD) deęişen oranlarını vurgulayarak 2023'ten 2037'ye kadar ayrıntılı tahminler sunmaktadır. Bunu başarmak için, yeşil teknolojinin ilerlemesinin nasıl tahmin edilebileceğine dair yeni kanıtlar sunmak üzere Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli kullanılmıştır. Ampirik verilere dayanan çalışma, ülkeleri yüksek, orta ve düşük GTD büyümesi olarak kategorize etmektedir. Bulgular, Japonya, Almanya ve ABD'nin GTD'de önemli bir büyüme yaşayacağını, Avustralya, Kanada ve Meksika gibi ülkelerin ise ılımlı artışlar göreceğini göstermektedir. Buna karşılık, İrlanda ve İzlanda gibi bazı ülkeler düşük veya negatif GTD değerleriyle zorluklarla karşılaşmaktadır. Çalışma, bu makine öğrenimi modelinin uygulanmasının, kendi ülkelerinde yeşil teknolojinin benimsenmesini artırmayı amaçlayan politika yapımcılar için deęerli içgörüler ve gelecek tahminleri sağladığı sonucuna varmaktadır.

Öz

Sürdürülebilir kalkınmaya doğru hızlanan küresel deęişim, yeşil teknolojilerin yaygınlaşmasını, özellikle OECD ekonomileri içinde, kritik bir odak alanı haline getirmiştir. Bu çalışma, OECD ülkeleri genelinde yeşil teknolojinin gelecekteki yaygınlaşmasını keşfetmek için bir makine öğrenmesi yaklaşımı kullanmayı amaçlamaktadır. Farklı uluslar arasında deęişen yeşil teknoloji yaygınlaşma (GTD) oranlarını vurgulayarak 2023'ten 2037'ye kadar ayrıntılı tahminler sunmaktadır. Bunu başarmak için, yeşil teknolojinin ilerlemesinin nasıl tahmin edilebileceğine dair yeni kanıtlar sunmak için Otoregresif Entegre Hareketli Ortalama (ARIMA) modeli kullanılmaktadır. Çalışma, ampirik verilere dayanarak ülkeleri yüksek, orta ve düşük GTD büyümesi olarak kategorize etmektedir. Bulgular, Japonya, Almanya ve ABD'nin GTD üzerinde önemli bir büyüme yaşayacağını, Avustralya, Kanada ve Meksika gibi ülkelerin ise orta düzeyde artışlar göreceğini göstermektedir. Tersine, İrlanda ve İzlanda dahil olmak üzere bazı uluslar, düşük veya negatif GTD değerleriyle zorluklarla karşı karşıyadır. Çalışma, bu makine öğrenmesi modelinin uygulanmasının, kendi ülkelerinde yeşil teknoloji benimsenmesini artırmayı amaçlayan politika yapımcılar için deęerli içgörüler ve gelecek tahminleri sağladığı sonucuna varmıştır.

Anahtar Kelimeler:

Sürdürülebilir
Kalkınma, Yeşil
Teknoloji Yayılımı,
Çevresel
Sürdürülebilirlik,
Makine Öğrenmesi
Analizi, ARIMA
Modeli.

JEL Kodları:

O3, O33, Q55

Anahtar Kelimeler:

Sürdürülebilir Kalkınma,
Yeşil Teknoloji
Yayılımı, Çevresel
Sürdürülebilirlik,
Makine Öğrenimi
Analizi, ARIMA
Modeli.

JEL Kodları:

O3, O33, Q55

* Yrd. Prof. Dr., OSTİM Teknik Üniversite, Departman . Ekonomi, Türkiye,
busra.agan@ostimteknik.edu.tr

Alındığı Tarih (Makale Geliş Tarihi): 08.07.2024

Kabul Tarihi (Makale Kabul Tarihi): 01.09.2024 Bu

makale Creative Commons Attribution 4.0 Uluslararası Lisansı ile lisanslanmıştır.



1. Giriş

Yeşil teknolojiler, küresel toplum iklim değişikliği ve çevresel bozulma gibi acil sorunlarla yüzleşirken sürdürülebilir kalkınmaya geçişte kritik bir faktör olarak ortaya çıkmıştır. Bu teknolojilerin benimsenmesi, karbon emisyonlarının azaltılması, enerji verimliliğinin artırılması ve Paris Anlaşması gibi uluslararası anlaşmalarla belirlenen çevresel hedeflere ulaşılması için elzemdir. Bu bağlamda OECD ekonomileri, ekonomik etkileri ve teknolojik yenilikçilik kapasiteleri nedeniyle çok önemli bir rol oynamaktadır. Yeşil enerji kaynakları, enerji verimli sistemler ve sürdürülebilir tarım uygulamalarını içeren bu teknolojiler, sera gazı emisyonlarını önemli ölçüde azaltma ve iklim değişikliğinin olumsuz etkilerini azaltma potansiyeline sahiptir. Bu teknolojilerin yayılması da en az yaratılmaları ve geliştirilmeleri kadar önemlidir. Öncü araştırmacılarından Hall (2004), inovasyonda yayılma kavramını inceleyerek, bireylerin ve firmaların yeni teknolojileri nasıl benimsediklerini veya eski teknolojileri nasıl değiştirdiklerini açıklamaktadır. Difüzyonun sadece yenilikleri yaymakla kalmayıp aynı zamanda öğrenme, taklit ve geri bildirim etkileri yoluyla onları geliştirdiğine dair kanıtları desteklemektedir.

Yeşil teknolojilerin benimsenmesi ve yaygınlaştırılması, küresel ısınmayı sanayi öncesi seviyelerin 2 santigrat derece altında sınırlandırmayı amaçlayan Paris Anlaşması gibi uluslararası anlaşmalarla belirlenen hedeflere ulaşılması için elzemdir (UNFCCC, 2015). Rüzgâr ve güneş enerjisi gibi yeşil enerji teknolojilerinin yaygınlaştırılmasının, ekonomik faydalar ve enerji güvenliği sağlarken karbon emisyonlarını önemli ölçüde azaltabileceğini gösteren birçok çalışma bulunmaktadır (Rao ve Kishore, 2010; Sun vd., 2022; Luo vd., 2024). Rogers (2003) tarafından yapılan araştırma, yeşil teknolojilerin benimsenmesini kolaylaştırmak için yayılma sürecini anlamının önemini vurgulamaktadır. Roger'ın yeniliklerin yayılması teorisi, bir yeniliğin özelliklerinin, iletişim kanallarının, zamanın ve sosyal sistemin benimsenme oranını nasıl etkilediğini vurgulamaktadır. Bu çerçevenin yeşil teknolojilere uygulanması, benimsenmelerindeki engelleri ve hızlandırıcıları belirleyerek çeşitli sektörlere daha etkili bir şekilde yayılmasını ve entegrasyonunu sağlar.

Dutz ve Sharma (2012) tarafından yapılan bir başka çalışmada, yeşil teknolojilerin kaynak verimli, temiz ve dirençli ekonomik büyümeyi teşvik ederek temelde farklı yenilikleri kapsadığı analiz edilmiştir. Öte yandan, Dewick ve diğerleri (2006) 21. yüzyılda gelecekteki yıkıcı teknolojilerin endüstriyel yapı, ekonomik genişleme ve çevre üzerindeki etkisini araştırmıştır. AB, ABD ve Çin'deki teknolojileri 2020 ve 2050 yılları için analiz eden bulgular, AB ve ABD'nin benzer etkiler yaşayacağını, ancak Çin'in başlangıçta daha az etki göreceğini ve 2050 yılına kadar AB ve ABD ile aynı hizaya geleceğini göstermektedir.

Buna ek olarak, son çalışmalar yeşil teknolojilerin yayılmasını teşvik etmede politika ve düzenleyici çerçevelerin rolünü vurgulamaktadır. Örneğin, sübvansiyonlar, vergi teşvikleri ve yenilenebilir enerji zorunlulukları gibi destekleyici politikaların yeşil enerji teknolojilerinin yayılmasını önemli ölçüde artırdığı gösterilmiştir (Hao vd., 2021; Habiba vd., 2022; Sadiq vd., 2023; Zhou vd., 2023). Benzer şekilde, sıkı çevresel düzenlemeler, firmaları daha temiz teknolojiler geliştirmeye ve benimsemeye iterek inovasyonu teşvik edebilir (Meng vd., 2020; Wang vd., 2021; Luo ve Mabrouk, 2022).

GTD'nin kritik önemine rağmen, geleneksel tahmin yöntemleri, çeşitli ekonomik ortamlarda teknolojinin benimsenmesinin karmaşık ve dinamik doğasını yakalamada genellikle yetersiz kalmaktadır. Son yıllarda, makine öğreniminin (ML) ortaya çıkışı, büyük veri kümelerini analiz edebilen ve aşağıdakileri ortaya çıkarabilen gelişmiş metodolojiler sunarak tahmine dayalı analitikte devrim yaratmıştır

karmařık modeller. Daha yakın zamanlarda, yeřil teknoloji tahmininde makine öğrenimi ve yapay zeka bağlantıları, yeniliklerin yayılmasını tahmin etme yeteneğini daha da geliřtirmiřtir. Zhou ve diğerkleri (2024), endüstriyel robotların benimsenmesinin Çin'deki bölgesel kirlilik emisyonları üzerindeki etkisini arařtırmıřtır. Bulgular, endüstriyel robotların çeřitli illerde kirlilik emisyonu yoğunluğunu önemli ölçüde azalttığını ve bunun saėlamlık testleriyle doėrulandığını göstermektedir. Bu analiz, bu azalmanın geliřmiř enerji verimliliėi ve artan kirlilik azaltma teknolojilerinden kaynaklandığını ortaya koymaktadır. Ayrıca, Han ve Yang (2024) Çinli bir yenilenebilir enerji řirketinde yapay sinir aėı (YSA) kullanarak finansman ve yönetim stratejilerini arařtırmıř, çalışmada yeřil iřlerin artırılmasının CO2 emisyonlarını yenilenebilir enerji kapasitelerinin artırılmasından daha önemli ölçüde azalttığını bulunmuřtur.

Bu çalışma, OECD ekonomilerinde yeřil teknolojilerin yayılımını tahmin etmek için makine öğrenimi yaklařımlarının uygulanmasına odaklanmaktadır. Bu modelin yeřil teknoloji tahminine yeni bir şekilde uygulanması, daha doėru ve güvenilir tahminler yapılmasına olanak saėlamaktadır. Bu amaçla, çalışmada yeřil teknolojilerin yayılma modellerini modellemek ve tahmin etmek için denetimli öğrenme algoritmaları ve topluluk yöntemleri de dahil olmak üzere bir dizi makine öğrenimi tekniėi kullanılmaktadır. ARIMA modeli, zaman serisi tahminindeki saėlamlığı ve teknoloji yayılımında yer alan karmařık dinamikleri ele alma kabiliyeti nedeniyle sečilmiřtir. Tahminlerimizin doėruluėunu ve güvenilirliğini saėlamak için tarihsel benimseme oranlarını, ekonomik göstergeleri ve çevre politikalarını kapsayan kapsamlı bir veri seti kullandık. Bu nedenle, bu çalışmanın tahminleri mevcut (1980-2022) ve gelecek (2023 ve 2037) yıllar olarak ikiye ayrılmıřtır.

Bu çalışmanın önemi, politika yapımcılar, iřletmeler ve arařtırmacılar için uygulanabilir içgörüler saėlama kabiliyetinde yatmaktadır. Bu çalışma, makine öğrenimi tekniklerini ekonomik tahmin modelleriyle çeřitli şekillerde entegre ederek teknoloji yayılımı ve sürdürülebilirlik konusundaki mevcut literatüre önemli bir katkı saėlamaktadır. İlk olarak, OECD ülkeleri bağlamında yeřil teknolojinin gelecekteki yayılımını tahmin etmeye odaklanmaktadır. İkinci olarak, yeřil teknolojinin gelişiminden ziyade yayılımını vurgulamaktadır. Üçüncüsü, geliřmiř makine öğrenimi yöntemlerini dahil ederek teknolojik yayılım anlayışını geliřtirmekte ve böylece mevcut modellerin tahmin yeteneklerini iyileřtirmektedir. Bu çalışmanın arka planı, hedefleri ve önemi göz önüne alındığında, arařtırma ařaėıdaki temel soruyu ele almayı amaçlamaktadır: GTD önümüzdeki 14 yıl içinde OECD ülkelerinde nasıl bir gelişme gösterecek?

Bu çalışmanın ayırt edici özelliėi, ML tekniklerini, özellikle de Otoregresif Bütünleşik Hareketli Ortalama (ARIMA) modelini kullanmasından kaynaklanmaktadır. Bu yöntem, 2023'ten 2037'ye kadar OECD ülkelerinde yeřil teknolojinin yayılmasının tahmin edilmesine yönelik yeni bilgiler sunmaktadır. ARIMA kullanımı, zaman serisi verilerinin ayrıntılı bir şekilde incelenmesine olanak tanıyarak, geleneksel yöntemlerin gözden kaçırabileceėi eğilim ve kalıpların incelikli bir şekilde anlaşılmasını saėlar. ARIMA modelinin bulgularına göre, çoėu ülke GTD'de artan bir eğilim gösteriyor ve bu da tahmin dönemi boyunca yeřil teknolojinin benimsenmesi için umut verici bir geleceėe iřaret ediyor. Bu yaklařım sadece tahminlerin doėruluėunu artırmakla kalmamakta, aynı zamanda OECD ülkeleri genelinde yeřil teknolojinin benimsenme dinamikleri ve bunun sürdürülebilirlik ve ekonomik kalkınma açısından gelecekteki etkileri hakkında deėerli kanıtlar sunmaktadır.

Çalışma ařaėıdaki şekilde yapılandırılmıřtır: Bölüm 2'de teknoloji yayılımı ve tahminlemede makine öğrenimi ile ilgili literatür incelenmektedir. Bölüm 3, ARIMA modeli ve kullanılan veriler dahil olmak üzere metodolojiyi detaylandırmaktadır. Bölüm 4 ampirik sonuçları sunmaktadır. Bölüm 5, temel bulguları özetleyerek, kısıtlamaları tartıřarak ve politika önerileri sunarak çalışmayı sonlandırmaktadır.

2. Literatür Taraması

Yeşil teknolojilere geçiş, iklim değişikliğinin ele alınması ve sürdürülebilir kalkınmanın teşvik edilmesi açısından büyük önem taşımaktadır. Yeşil teknolojinin gelişimini ve yayılmasını sağlayan faktörleri inceleyen teorik ve ampirik çalışmalar giderek artmaktadır. Bu literatür, genel olarak yeşil teknolojiler ve CO2 emisyonları arasındaki bağlantılara odaklanmaktadır. Ayrıca, yeşil teknolojilerin benimsenmesinde ekonomik büyüme ve çevresel bozulma arasındaki ilişkiyi bağlamsallaştırmak için Çevresel Kuznets Eğrisi (EKC) çerçevesini de içermektedir. Önceki literatürden farklı olarak, bu literatür taraması GTD üzerine mevcut teorik ve ampirik araştırmaları incelemekte, bu yayılımın belirleyicilerini vurgulamakta ve tahmin doğruluğunu artırmada makine öğreniminin ortaya çıkan rolünü araştırmaktadır.

Yeşil teknolojilerin yayılımı çeşitli teorik çerçeveler dahilinde kapsamlı bir şekilde incelenmiştir. Rogers'ın (2003) "Yeniliklerin Yayılımı" teorisi, yeni teknolojilerin bir toplum içinde nasıl yayıldığına dair temel bir anlayış sunmakta ve göreceli avantaj, uyumluluk, karmaşıklık, denenebilirlik ve gözlemlenebilirlik gibi faktörleri vurgulamaktadır. Bu teori, algılanan fayda ve engellerin önemini vurgulayarak yeşil teknolojilerin benimsenmesini incelemek için uyarlanmıştır (Hall ve Khan, 2003). Bir diğer önemli teorik çerçeve ise 1990 yılında Tornatzky ve Fleischer tarafından geliştirilen Teknoloji-Organizasyon-Çevre (TOE) çerçevesidir. Bu model teknolojik, örgütsel ve çevresel bağlamları teknolojik yeniliklerin benimsenmesinin kritik belirleyicileri olarak görmektedir. Yeşil teknolojiler bağlamında TOE çerçevesi, yayılımı etkileyen teknolojik hazırlık, örgütsel yetenekler ve düzenleyici baskılar gibi faktörleri tanımlamaktadır.

Popp (2006) tarafından yapılan bir araştırmaya göre enerji verimliliği standartları ve emisyon azaltımları da yeşil teknolojileri yönlendirmektedir. Teorik çerçeveye ek olarak, Allan ve diğerleri (2013) yeşil teknolojinin benimsenmesini etkileyen ekonomik, düzenleyici, sosyal ve teknolojik faktörler üzerine yeşil teknolojinin yayılma aşamalarını araştırmıştır. Ayrıca maliyetler ve farkındalık eksikliği gibi engelleri tespit etmişler ve çevre dostu yeniliklerin yayılmasını teşvik etmek için finansal teşvikler, düzenleyici destek, kamuoyu bilinçlendirme kampanyaları ve araştırma ve geliştirme önermektedirler. Daha sonra, Cohen ve diğerleri (2017) finansal kaynakların mevcudiyetinin ve sermaye piyasalarına erişimin yeşil teknoloji yatırımlarının kritik belirleyicileri olduğunu belirtmektedir.

Literatürdeki çalışmaların çoğu, GTD'nin ampirik etkileri ve sonuçları üzerine yoğunlaşmıştır. Önceki çalışmalarda, Lv ve diğerleri (2021) 30 Çin şehrinde yeşil inovasyon verimliliğini ölçerek finansal yapı, ölçek ve verimliliğin etkisini incelemiştir. Bulgular, finansal yapının yeşil teknoloji inovasyonunu teşvik ettiğini, finansal ölçek ve verimliliğin ise bunu engellediğini, çevresel düzenleme ve inovasyon çıktısının ise ılımlı ve aracı roller oynadığını göstermektedir. Benzer şekilde, Xu ve diğerleri (2021) 13 Çin imalat sektöründe yeşil düzenleme ve doğrudan yabancı yatırımın (FDI) yeşil inovasyon üzerindeki etkilerini analiz etmiştir. Sonuçlar, ekolojik düzenlemenin yeşil inovasyonu olumlu yönde, doğrudan yabancı yatırımın ise olumsuz yönde etkilediğini göstermektedir. Daha sonra, Maiti (2022) 32 ülkeden elde edilen veriler üzerinde dinamik panel eşik regresyonu kullanarak yeşil büyümenin yeşil inovasyon üzerindeki etkisini araştırmış ve bulgular CO₂ verimliliğindeki %1'lik bir artışın yeşil inovasyonu artırdığını ve ayrıca çevresel verimlilikteki %1'lik bir artışın yeşil teknolojileri geliştirdiği sonucuna varmıştır.

Hussain ve diğerleri (2022b) tarafından yapılan mevcut bir çalışma, yüksek GSYİH'li ülkelerde çevresel teknoloji ve yeşil faktörlerin yeşil büyüme üzerindeki rolünü araştırmaktadır. Ampirik bulguları, yeşil teknolojinin önemli ölçüde çevre dostu büyümeyi artırdığını, ancak enerji

tüketim ve emisyonları azaltmaktadır. Ayrıca, Tuganova ve diğeri (2022) yeşil teknolojinin sürdürülebilir kalkınma üzerindeki etkisini Scopus ve Avrupa Patent Ofisi'nden alınan veriler üzerinde bibliyometrik yöntemler kullanarak incelemiştir. Bulguları, bu eko-inovasyon alanlarında artan arařtırmaların mutlaka daha fazla patente yol açmadığına dair kanıtlar sunmakta ve yeşil teknolojilerin çevresel zorlukları çözmedeki etkinliği konusundaki şüpheciliği vurgulamaktadır. Lin ve Ma (2022), 264 Çin şehrinde yeşil teknoloji inovasyonlarının CO₂ emisyonları üzerindeki etkisini arařtırmış ve kentsel inovasyon ortamının bu ilişkiyi nasıl etkilediğine odaklanmıştır. Bulgular, yeşil inovasyonların CO₂ emisyonlarını yalnızca 2010 yılından sonra önemli ölçüde azalttığını ortaya koymaktadır. Öte yandan, hükümet harcamaları yeşil teknolojilerin marjinal etkisini önemli ölçüde değiřtirmemekte ve etkin CO₂ azaltımı için beşeri sermayenin öneminin altını çizmektedir.

Oyebanji ve Kirikkaleli (2023) tarafından yapılan bir başka çalışmada, Batı Avrupa ülkelerinde yeşil teknoloji inovasyonu, yenilenebilir elektrik, finansal kalkınma ve ekonomik genişlemenin çevre kalitesi üzerindeki etkisi arařtırılmıştır. Sonuçlar, yenilenebilir elektriğin ve yeşil teknolojilerin CO₂ emisyonlarını azalttığını göstermektedir. Yeni yaklaşım bağlamında Wang ve diğeri (2023), yapay zekanın (YZ) 51 ülkede sürdürülebilir kalkınma hedefleriyle ilişkili olarak yeşil inovasyonu nasıl etkilediğini arařtırmıştır. Bulguları, yapay zeka ile yeşil inovasyon arasında güçlü bir pozitif korelasyon olduğunu ortaya koymakta ve yapay zekanın çevresel inovasyonu teşvik etmede çok önemli olduğunu vurgulamaktadır.

Ekonomik faktörler yeşil teknolojilerin yayılmasında önemli bir rol oynamaktadır. Çalışmalar, sübvansiyonlar, vergi kredileri ve hibeler gibi ekonomik teşviklerin yenilenebilir enerji teknolojilerinin benimsenmesini önemli ölçüde etkilediğini göstermiştir. Johnstone ve diğeri (2010) tarafından yapılan bir çalışma, sübvansiyonlar, vergi kredileri ve hibeler gibi ekonomik teşviklerin yenilenebilir enerji teknolojilerinin benimsenmesini önemli ölçüde etkilediğini göstermektedir. Shen ve diğeri (2021) ekonomik büyüme hedeflerinin belirlenmesinin bölgesel yeşil teknoloji inovasyonunu nasıl etkilediğini değerlendirmiştir. Elde ettikleri sonuçlar, hedeflerin yeşil teknoloji inovasyonunu önemli ölçüde engellediği, hızlı ekonomik büyümeye ve yüksek hedef aşımına sahip şehirlerde daha güçlü bir etkiye sahip olduğu sonucuna varmıştır.

Aynı şekilde, Luo ve diğeri (2024) yeşil teknoloji inovasyonunun Çin'deki ekonomik büyüme üzerindeki etkisini analiz etmiş ve bulgular yeşil teknolojilerin Çin'deki GSYİH büyümesini önemli ölçüde artırdığı sonucuna varmıştır. Wang ve diğeri (2023b) ekonomik kalkınma baskısının Çin'in şehirlerindeki yeşil toplam faktör verimliliğini nasıl etkilediğini ve yöntemlerini arařtırmıştır. Bulgular, ekonomik büyümenin yeşil teknoloji ilerlemesini ve verimliliğini etkilediğini ve ilerleme üzerinde daha güçlü bir etkiye sahip olduğunu göstermektedir. Ayrıca, Tsimisaraka ve diğeri (2023) yeniliklerin ve ekonomik genişlemenin CO₂ emisyonları üzerindeki potansiyel faktörlerle kısa ve uzun vadeli etkilerini arařtırmış ve ampirik bulgular yeniliklerin ekonomik büyüme ile pozitif ilişkili olduğunu göstermiştir. Son olarak, Ciccarelli ve Marotta (2024) iklim değişikliği, çevre politikaları ve yeşil inovasyonun etkisini analiz etmekte ve bulgular, yıkıcı etkilerin sınırlı çevre politikaları olan veya doğal afetlere yüksek oranda maruz kalan düşük gelirli, yüksek emisyonlu ülkelerde daha şiddetli olduğuna dair kanıtlar sunmaktadır.

Çevre politikaları ve GTD arasındaki etkileşimlerle ilgili olarak, hükümet politikaları ve düzenlemeler yeşil teknolojilerin yayılımını şekillendirmede çok önemlidir. Hussain ve diğeri (2022a) tarafından incelendiği üzere, tarife garantisi, yenilenebilir portföy standartları ve karbon fiyatlandırma mekanizmaları gibi politika araçlarının yenilenebilir enerji teknolojilerinin benimsenmesini teşvik ettiği gösterilmiştir. Ayrıca, Zhang ve diğeri (2021) seçilmiş ülkelerde kamu harcamalarının yeşil ekonomik büyüme ve enerji verimliliği üzerindeki etkisini analiz etmiştir. Bulgulara göre yeşil

ekonomik büyüme, tutarsız hükümet politikaları nedeniyle dalgalanmaktadır. Chen ve diğerleri (2022) Çin şehirlerinde çevresel düzenlemelerin yeşil teknoloji inovasyonu üzerindeki etkisini araştırmıştır. Ampirik bulguları, karbon emisyonları ve hava kirliliğine ilişkin hükümet düzenlemelerinin yeşil teknoloji inovasyonunu olumlu yönde etkilediğini ve "Porter Hipotezi"ni desteklediğini göstermektedir.

Benzer şekilde, Chen ve Tanchangya (2022) Çin'de yeşil teknoloji ve politika sıklığının yeşil büyüme üzerindeki rolünü araştırmıştır. Bulguları, çevre politikası sıklığının kısa vadede yeşil ekonomik büyümeyi olumsuz etkilediğine ve uzun vadede önemli bir etki göstermediğine dair kanıtlar sunmaktadır. Afshan ve diğerleri (2023) tarafından yapılan bir başka çalışmada yeşil finans, eko-inovasyon ve çevre politikası sıklığının Çin'in ekolojik ayak izi üzerindeki etkisi değerlendirilmiştir. Bulgular, eko-inovasyon, yeşil finans ve çevre politikası sıklığının ekolojik ayak izini olumlu yönde etkilediğini ortaya koymaktadır. Japonya'da güneş enerjisinin benimsenmesini tahmin etmek için sinir ağlarını kullanan Nakano ve Washizu'nun (2022) çalışması gibi son çalışmalar makine öğrenimini geleneksel ekonometrik yöntemlerle birleştirmeyi keşfetmeye başlamış olsa da, bu yaklaşımlar özellikle OECD ekonomileri bağlamında henüz başlangıç aşamasındadır.

ML yaklaşımı dikkate alındığında, birkaç çalışma yeşil teknolojilerin benimsenmesi ve yayılması ile bunların potansiyel ilgili belirleyicileri arasındaki ilişkiyi incelemektedir. Örneğin, Magazzino ve diğerleri (2021) ileri ML teknikleri kullanarak güneş ve rüzgar enerjisi üretimi, kömür tüketimi, ekonomik genişleme ve CO₂ emisyonları arasındaki nedensel ilişkileri tahmin etmektedir. Tahminleri, Çin ve ABD'nin artan yenilenebilir enerji kullanımı nedeniyle CO₂ emisyonlarını azaltması beklenirken, Hindistan'ın emisyonlarda bir artış görmesinin öngörüldüğünü ortaya koymaktadır. Ayrıca, Magazzino ve diğerleri (2021) Bilgi ve İletişim Teknolojileri (BİT) ile çevre kirliliği arasındaki ilişkileri seçilmiş OECD ülkelerinde bir ML algoritması aracılığıyla araştırmıştır. ML bulguları, BİT'in CO₂ emisyonlarına önemli ölçüde katkıda bulunduğunu doğrulamaktadır. Peiró-Signes ve diğerleri (2022) tarafından yapılan bir başka çalışmada, yenilikçi firmaların çevresel yönetimlerini analiz etmek için bir XGBoost modeli ve ML metodolojileri kullanılmıştır. Tahminleri, eko-yenilikçi bir kültürün teşvik edilmesinde politika düzenlemelerinin ve yönetim stratejilerinin önemini ortaya koymaktadır.

Yakın zamanda, Zhou ve diğerleri (2024) endüstriyel robotların Çin'deki bölgesel kirlilik üzerindeki etkisini tahmin etmiştir. Tahminleri, endüstriyel robotların çeşitli eyaletlerdeki kirlilik yoğunluğunu önemli ölçüde azalttığını vurgulamaktadır. Daha sonra, Aminullah, (2024) sistem dinamikleri modellemesi yoluyla teknoloji inovasyonu ve ekonomik büyümeyi tahmin etmektedir. Genel Amaçlı Teknolojilere (GPT'ler) yapılan yatırımların sanayi politikasıyla ilişkilendirilmesinin, özellikle COVID-19 sonrası bağlamda, kapsayıcı büyüme ve sürdürülebilir kalkınma için çok önemli olduğunu vurgulamaktadır. Ayrıca, Zhao ve diğerleri (2024) 108 şehirden panel verileri kullanarak çevresel kaliteyi araştırmaktadır. Bulguları, yeşil teknolojik inovasyonun kirliliğin azaltılmasını ve karbon verimliliğini önemli ölçüde iyileştirdiğini ortaya koymaktadır.


Ayrıca, Sun ve diğerleri (2024) rastgele orman tahmini ve sıradan en küçük kareler modellerini kullanarak Çin şehirlerindeki düşük karbonlu teknolojik yenilikler üzerindeki karbon baskısının tahminini araştırmaktadır. Tahminleri, nüfus büyüklüğü ve ekonomik kalkınmanın düşük karbonlu inovasyonu önemli ölçüde teşvik ettiğini desteklemektedir. Daha da önemlisi, önceki çalışmalar (Hübler, 2011; Lee ve Yang, 2018; Zhang vd., 2020; Bessi vd., 2021; Shahzad vd., 2022; Ahmad vd., 2023) da ML yaklaşımlarını kullanarak GTD tahminini araştırmaktadır.

GTD üzerine yapılan araştırmaların giderek artmasına rağmen, bu teknolojilerin gelecekteki yayılımını tahmin etmek için gelişmiş makine öğrenimi tekniklerinin uygulanmasında önemli bir boşluk bulunmaktadır.

OECD ekonomileri. Bu alıřma, ARIMA modelini tahmin srecine entegre ederek, yayılım tahminlerinin doėruluėunu ve uygunluėunu artıracak yeni bir metodolojik yaklařım saėlayarak bu bořluėu doldurmayı amalamaktadır. Ayrıca, OECD lkelerinin zel baėlamına odaklanan bu alıřma, srdrlebilirlik gndemlerinin bir parası olarak yeřil teknolojinin benimsenmesini teřvik etmekle grevli olan bu lkelerdeki politika yapıcılar iin doėrudan uygulanabilir igrler sunmaktadır.

3. Veri ve Metodoloji

Bu alıřmada 38 OECD lkesi iin 1980'den 2022'ye kadar yıllık veriler kullanılmıřtır. Bu dnemler veri mevcudiyetine gre seilmiřtir. GTD, OECD istatistiklerinden alınan patent bařvuralarına dayanmaktadır. Bu veriler, teknolojik yenilik ve yeni yeřil teknoloji buluřlarının sıklıėı hakkında fikir vermektedir. zellikle řekil 1, 1980'den 2022'ye kadar OECD lkelerindeki genel GTD seviyelerinin zaman serisi gsterimini gstermektedir.



řekil 1. Yeřil Teknoloji Yayılımı Yeřil Teknoloji Yayılımı, 1980-2022

3.1. Makine ėrenimi

Makine ėrenimi, belirli bir konudaki verilere dayalı algoritmalar oluřtırmaya, yeni veriler elde edildike ıktıları gncellemeye ve sonuları tahmin etmek iin istatistiksel analiz kullanmaya dayanır. Makine ėrenimi altında bilgisayarların ėrenmesini saėlayan birok farklı algoritma tr vardır. Bilgisayarlar eřitli fonksiyonlar ve istatistiksel yntemler kullanarak ėrenilen verilerden bir model ıkarır ve bu modele gre yeni verileri tahmin edebilir, ngrebilir veya sınıflandırabilir. Literatrde birok farklı ML yntemi bulunmaktadır. Bu yntemler veri trne baėlı olarak farklı performans gsterir. Bu nedenle bir makine ėrenimi ynteminin diėerlerinden stn olduėunu sylemek zordur. Makine ėrenmesinde  temel ařama vardır. Bunlar

1. Verilerin hazırlanması: İlk adım doėru verilerin hazırlanmasıdır ve doėru sonulara ulařabilmek iin verilerin titizlikle hazırlanması gerekir. Bu ařamada aykırı deėerler bulunarak, veriler normalize edilerek vb. veriler iřlenmeye hazır hale getirilir. Problemin trne baėlı olarak hem sayısal hem de sembolik (nominal) veriler iřlenebilir.

2. Eğitim: İkinci aşama ise en uygun modelin bulunması ve ilk aşamada hazırlanan verilerin bu model ile eğitilmesidir. Öncelikle probleme uygun bir makine öğrenmesi yöntemi seçilir ve eğitim ile verilerden en uygun model oluşturulur. Uygun modeli bulmak için mümkün olduğunca çok sayıda model kurulmalı ve test edilmelidir. Eğitim setindeki verilerin bir kısmı çıkarılarak model doğrulanır ve modelin uygun olup olmadığına karar verilir.
3. Test etme: Son aşama ise performans testidir. Bunun için modelin oluşturulmasında kullanılan eğitim verileri dışındaki verilerle oluşturulan model kullanılarak model test edilir. Bu verilere test seti adı verilir. Test sürecinde ML'nin test seti ile gösterdiği performans doğruluk oranı, yanlış pozitif sayısı, doğru pozitif sayısı gibi metriklerle ölçülür.

ML sınıflandırma, regresyon ve kümeleme için kullanılır, ancak zaman serisi analizi için de sıklıkla kullanılır. ML ve zaman serileri, geçmişten gelen bilgilere dayanarak yeni tahminler yapmaya çalışır. Bu, makine öğreniminde bir tür denetimli öğrenmedir. Bu çalışmada, başarılı sonuçlar verdiği bilinen bir ML yöntemi olan ARIMA kullanılarak zaman serisi analizi gerçekleştirilmiştir.

3.2. Zaman Serisi Analizi

Zaman serisi analizi, gözlemlenen örüntüleri yönlendiren altta yatan faktörleri anlamayı amaçlayarak, gözlemlenen bir zaman serisini etkili bir şekilde temsil eden veya tanımlayan modeller oluşturmayı gerektirir. Zaman serisi analizinin temel amacı, örnek verilere dayanarak güvenilir açıklamalar sunabilen matematiksel modeller formüle etmektir. Bu modeller yalnızca geçmiş verilerin yorumlanmasına yardımcı olmakla kalmaz, aynı zamanda çeşitli alanlara uygulanabilen doğru tahmin, eğilimlerin belirlenmesi ve verilerin zamansal dinamiklerinin anlaşılmasını sağlar.

3.3. Zaman Serisi Tahmini

Bir zaman serisi tahmin modelinin etkinliği, gelecekteki değerleri ne kadar iyi tahmin ettiğiyle ölçülür. Bu değerlendirme, belirli tahminlerin arkasındaki nedenleri açıklığa kavuşturmaya, güven aralıklarını yorumlamaya veya altta yatan sorunlara ilişkin içgörü kazanmaya yardımcı olabilir. Zaman serisi verileri denetimli bir öğrenme problemi olarak çerçevelenebilir. Bir önceki zaman adımını girdi değişkeni ve bir sonraki zaman adımını çıktı değişkeni olarak kullanarak, zaman serisi veri setini denetimli öğrenmeye uygun bir formata dönüştürebiliriz.

3.4. Performans Ölçütlerinin Tahmini

Zaman serisi tahmin performans ölçütleri, tahmin modelinin etkinliğini ve doğruluğunu özetler. Değerlendirme için çok sayıda metrik mevcuttur ve zaman serisi tahmini genellikle gerçek değerlerin tahmin edilmesini içerdiğinden - genellikle regresyon problemleri olarak kategorize edilir - bu makale özellikle gerçek değerlerin tahminlerini değerlendirmek için tasarlanmış metriklere odaklanacaktır.

3.5. Ortalama Mutlak Hata

Ortalama mutlak hata (MAE), tüm hata deęerleri pozitif olarak deęerlendirilerek tahmin hatalarının ortalaması olarak hesaplanır. Mutlaklařtırma olarak bilinen bu iřlem, tüm hataların pozitif olmasını saęlar. MAE'nin sıfır olması hatasız mükemmel doęruluęu gösterir.

$$MAPE = \frac{\sum_{t=1}^n |y_t - \hat{y}_t|}{n} \cdot 100 \quad (1)$$

3.6. Ortalama Karesel Hata

Ortalama karesel hata (MSE), tahmin hatalarının karesel deęerlerinin ortalaması alınarak belirlenir. Bu hataların karesinin alınması pozitif olmalarını saęlar ve orantısız bir řekilde daha büyük hataları vurgular. Hata deęerleri, tahminlerin kareli birimleri cinsinden ifade edilir. MSE'nin sıfır olması mükemmel doęruluk veya hatasızlık anlamına gelir.

$$MSE = \frac{\sum_{t=1}^n (y_t - \hat{y}_t)^2}{n} \quad (2)$$

3.7. Ortalama Karesel Hata Kökü

Daha önce açıklanan MSE, tahminlere göre kareli birimler halinde sunulur. Tahminlerin orijinal birimlerine geri dönmek için MSE'nin karekökü hesaplanabilir, bu da kök ortalama kare hata (RMSE) ile sonuçlanır. MSE gibi RMSE'nin de sıfır olması hata olmadığını gösterir.

$$RMSE = \sqrt{\frac{\sum_{t=1}^n |y_t - \hat{y}_t|^2}{n}} \quad (3)$$

3.8. Otoregresif Bütünleşik Hareketli Ortalama Modeli

ARIMA modeli, zaman serisi verilerini analiz etmek ve tahmin etmek için kullanılan istatistiksel bir yaklaşımdır. ARIMA'nın kısaltması olan ARIMA, üç unsuru bir araya getirir: otoregresyon, fark alma ve hareketli ortalamalar. Spesifik olarak, bir gözlem ile bir dizi gecikmeli gözlem arasındaki bağımlı ilişkiyi, AR (otoregresyon), I (entegre), ham gözlemlerin farklılaştırılması ve zaman serisini durağanlařtırmak için MA (hareketli ortalama) kullanan bir modeldir. ARIMA ile tahmin genellikle üç ana adımdan oluşur: zamansal modelin tanımlanması, parametrelerin tahmin edilmesi ve tanısal kontrol. ARIMA modeli (p, d, q) olarak gösterilir; burada her parametre, kullanılan belirli ARIMA modelini tanımlamak için bir tamsayı ile deęiřtirilir. Parametreler řu řekilde tanımlanır: p, gecikme sırası olarak da adlandırılan modeldeki gecikme gözlemlerinin sayısıdır; d, farklılařtırma derecesi olarak bilinen ham verilere uygulanan farkların sayısıdır; ve q, hareketli ortalama penceresinin boyutu veya hareketli ortalamanın sırasıdır. Modeli deęerlendirmek için MAPE, MSE ve RMSE gibi tahmin ölçütleri kullanılmıřtır. ARIMA algoritması, farklı modeller oluřtırmak için yazarlar tarafından geliřtirilen bir optimizasyon algoritması kullanılarak tekrar tekrar çalıştırılmıřtır. Bir ARIMA modeli, bir eęitim veri kümesi üzerinde eęitilerek ve tahminleri bir test veri kümesi üzerinde test edilerek deęerlendirilir.

Bu çalışmada, zaman serisi tahmini için saęlam bir makine öğrenimi yaklařımı olan ARIMA modelini kullanıyoruz. ARIMA modeli, zaman serilerini yakalamadaki kanıtlanmış etkinlięi nedeniyle seçilmiřtir.

Verilerdeki zamansal bağımlılıklar ve eğilimler. Önceki çalışmalarda kullanılanlar (Bass, 1969; Lee ve Song, 2007) gibi geleneksel ekonometrik modeller genellikle doğrusal ilişkiler varsayar ve teknoloji benimseme dinamiklerinin nüanslarını tam olarak yakalayamayabilir. ARIMA dahil olmak üzere makine öğrenimi modelleri, verilerdeki daha karmaşık ilişkileri ve etkileşimleri modelleyebilir ve yayılma modellerinin daha incelikli bir şekilde anlaşılmasını sağlar. Makine öğrenimi kullanımı, örüntü tanıma ve trend analizi gibi gelişmiş analitik yetenekleri de kolaylaştırır.


Veri kümesi iki parçaya ayrılmıştır: %66'sı ilk eğitim kümesi için ayrılırken, kalan %34'ü test için kullanılır. Her iterasyon yeni verileri tahmin edebilen bir model üretir. Yinelemeli yaklaşım, her zaman adımında yeni bir ARIMA modelini eğitir ve her yineleme sırasında tahminler yapılır ve bir listeye kaydedilir. Bu süreç, tüm tahminlerin test setinin sonundaki gerçek değerlerle karşılaştırılmasına olanak tanıyarak bir hata puanının, özellikle de RMSE'nin hesaplanmasını sağlar. Zaman serisi tahmin modelleri tahminler üretebilir ve ayrıca gerçek gözlemler için üst ve alt sınırları tanımlayan güven aralıkları sağlayabilir. Bu aralıklar, potansiyel sonuçların aralığını değerlendirmek ve modelin doğruluğunu değerlendirmek için kullanışlıdır.

Tahmin fonksiyonu güven aralığının belirlenmesine izin verir ve tahmin fonksiyonundaki alpha bağımsız değişkeni güven seviyesini belirler. Varsayılan olarak, alpha %95 güven aralığına karşılık gelecek şekilde 0,05 olarak ayarlanmıştır. Bu güven aralığının hem makul hem de yaygın olarak kabul edildiği düşünülmektedir. Alfa değerinin 0,05 olması, ARIMA modelinin tahminin üst ve alt sınırlarını, gerçek değer bu aralığın dışında kalma olasılığı yalnızca %5 olacak şekilde hesaplayacağı anlamına gelir. Bu yaklaşım, modelin tahminleriyle ilişkili belirsizliği anlamak için gereklidir ve tahminin çoğu zaman gerçek değeri kapsamamasını sağlar. Kullanıcılar alfa değerini ayarlayarak güven seviyesini belirli gereksinimleri karşılayacak şekilde değiştirebilir ve böylece risk değerlendirmesi ve karar verme süreçlerinde daha fazla esneklik sağlayabilirler.

Tahminler yapıldıktan sonra, ML yöntemlerinin veri kümesi üzerindeki tahmin başarısını ölçmek gerekir. Bu amaçlar için performans metrikleri geliştirilmiştir. MAPE, MSE ve RMSE gibi tahmin metrikleri modeli değerlendirmek için kullanılır (Sammur ve Webb, 2010). Lewis (1982) MAPE değeri %10'un altında olan tahminleri "çok iyi" olarak değerlendirmiştir. Basitlik ve bütünlük adına, bu makale model doğruluğu ile karşılaştırma için MAPE puanlarını sunmaktadır. Farklı modeller oluşturmak için ARIMA algoritması, yazar tarafından geliştirilen optimizasyon algoritması kullanılarak tekrar tekrar çalıştırılmıştır. Verimlilik sorunları kontrol edildikten sonra en verimli model kullanılmıştır.

4. Ampirik Bulgular

Modelin başarılı bir şekilde geliştirilmesinden sonra, sonuçların görsel temsilleri oluşturulmuştur. Şekil 1, bu makalede tartışılan modelleri doğrulamak için yeterli kanıt sağlamaktadır. Hem mevcut dönem (1980-2022) hem de gelecek dönem (2023-2037) için tahmin edilen emisyonları göstermektedir. Şekil 2, güven aralıklarını (tahminlerin üst ve alt sınırları) temsil eden gri tonlarını içermektedir. Ayrıca Tablo 1, tahmin değerlerinin daha net anlaşılmasını sağlamak için model geliştirme sırasında belirlenen modelleme hatası ve doğruluk metriklerini sunmaktadır. Tablo 1, OECD ülkelerinde 2023'ten 2037'ye kadar GTD için tahmin değerlerini MAPE, RMSE ve MSE gibi doğruluk ölçütleriyle birlikte sunmaktadır.



Şekil 2. 2023-2037 için Yeşil Teknoloji Yayılım Tahminleri

Tablo 1. OECD Ülkelerinde OECD Ülkelerinde 2023'ten 2037'ye Yeşil Teknoloji Yayılım Görünümü

Ülkeler/Yıl	2023	2024	2025	2026	2027	2028	2029	2030	2031	2032	2033	2034	2035	2036	2037	MAPE	RMSE	MSE
Avustralya	188.03	195.65	203.94	184.87	182.32	249.63	277.05	308.02	306.18	343.5	333.87	275.25	219.65	272.37	272.91	21.99%	110.59	12229.15
Avusturya	20.85	16.03	14.19	12.7	19.27	12.8	11.33	0.59	14.95	23.39	16.35	4.52	5.38	0.8	-0.84	60.75%	21.76	473.61
Belçika	28.52	31	39.33	40.3	47.87	59.53	53.28	54.49	57.57	61.82	71.99	69.23	73.55	78.06	88.36	974.68%	43.31	1876
Kanada	396.23	400.57	390.61	464.7	466.31	521.87	500.53	475.07	453.96	440.92	419.46	397.83	392.41	403.48	397.78	17.96%	114.61	13134.37
Şili	50.9	65.51	66.95	77.97	71.34	66.54	65.39	86.6	63.77	59.34	72.11	62.91	69.71	84.38	85.82	55.58%	25.75	662.82
Kolombiya	72.02	70.27	65.84	68.25	47.62	38.05	46.76	71.61	62.89	54.17	63.8	89.98	100.21	102.53	94.83	354.18%	48.63	2364.48
Kosta Rika	4.09	4	4.62	4.5	3.96	4.94	4.59	4.6	6.36	8.13	7.08	5.66	5.66	5.3	6.02	103.73%	2.76	7.59
Çekya	-2.82	-7.53	-11.19	-4.71	-18.75	-30.26	-29.99	-14.94	6.27	4.53	-0.42	4.21	1.72	-3.41	-4.58	135.88%	30.74	944.78
Danimarka	16.29	23.72	20.42	14.48	12.75	10.45	12.08	1.58	5.31	4.24	5.04	9.03	11.38	16.44	15.58	59.71%	6.89	47.4
Estonya	2.29	-0.72	1.5	1.84	0.97	1.86	0.07	-0.25	-0.25	-0.25	1.07	2.42	2.81	0.64	2.02	67.39%	1.42	2
Finlandiya	19.23	8.39	24.32	20.91	25.35	16.53	17.64	24.52	22.42	19.38	15.36	7.24	6.79	-7.1	9.54	101.71%	20.13	405.05
Fransa	165.93	148.37	150.96	102.39	87.12	85.08	56.1	26.59	11.61	-12.09	-13.76	-40.26	-53.62	-72.66	-67.81	90.52%	252.3	63653.07
Almanya	720.89	720.81	697.89	646.22	647.77	702.13	666.64	687.12	696.6	657.17	612.46	549.61	659.08	629.7	502.13	25.61%	253.38	64200.55
Yunanistan	7.33	10.99	5.66	12.61	8.21	4.53	9	6.34	11.46	7.24	10.13	5.4	4.96	9.06	3.51	40.94%	5.79	33.53
Macaristan	33.22	32.07	42.28	58.58	51.93	84.5	85.28	78.25	79.83	69.95	81.29	69.45	64.71	59.76	68.07	263.62%	37.46	1402.97
İzlanda	3.34	1.14	0.61	-0.17	0.96	0.64	2.39	1.09	1.4	0.54	1.3	1.93	1.55	0.61	1.56	72.28%	1.3	1.69
İrlanda	2.05	12.33	5.34	10.75	3.26	10.47	5.35	2.04	3.45	-1.46	-0.56	3.59	2.08	2.72	2.22	70.43%	3.72	13.84
İsrail	18.26	-0.21	43.78	51.48	14.38	-3.35	-24.58	-5.36	-6.64	-27.71	-8.5	-9.27	-6.32	-8.03	-20.79	225.41%	22.57	509.23
İtalya	84.75	73.47	43.67	37.32	34.63	74.89	110.67	72.65	54.35	64.84	91.59	82.26	74.11	64	35.03	1477%	54.08	2925.05
Japonya	2470.5	2399.8	2557.1	2203.9	1944.3	2321.7	2231.2	2171.3	2152.8	1875.8	1892.5	1875.3	1717.8	1686	1867.7	44.06%	1740.8	3030394
Letonya	5.51	5.52	3.69	5.07	4.73	4.42	4.76	6.12	4.63	9.08	7.57	5.64	7.5	6.6	4.86	133.15%	3.37	11.34
Litvanya	4.18	4.46	3.36	4.98	6.56	4.55	5.03	7.71	9.07	4.91	6.86	6.18	5.95	6.01	4.71	71.08%	2.34	5.49
Lüksemburg	69.57	76.86	81.35	83.37	83.9	88.39	90.78	86.05	87.37	91.89	116.96	132.65	141.23	147.32	150.91	3676%	93.96	8828.5
Meksika	166.15	195.21	197.38	222.05	220.42	310.47	324.29	272.98	261.65	240.11	284.83	281.06	257.46	275.45	273.29	40.19%	80.17	6427.88
Hollanda	79.32	89.37	90.3	67.95	57.22	72.22	55.16	59.14	47.35	55.79	64.55	82.25	76.8	90.65	94.74	43.64%	24.37	594.02
Yeni Zelanda	27.81	24.85	27.66	27.48	28.58	20.74	9.74	6.88	3.83	3.67	16.74	21.71	27.89	23.9	25.75	57.82%	25.63	656.82
Norveç	5.54	6.72	-8.72	-2.62	-5.31	-15.52	-2.81	-5.19	-9.14	-4.16	-7.7	-9.63	-11.83	-11.87	-27.02	154.69%	36.94	1364.61
Polonya	59.53	100.47	138.79	93.57	105.22	112.25	132.74	85.54	77.71	76.19	77.2	74.61	45.86	85.98	124.65	29.10%	40.45	1636.23
Portekiz	8.27	5.05	16.89	11.85	12.07	7.51	8.53	10.86	7.26	3.12	5.49	3.31	5.82	2.95	16.04	103.76%	5.57	31.05
Slovakya	5.01	12.08	5.83	4.27	3.32	-4.73	4.46	14.27	15.49	7.51	10.59	10.9	3.54	12.04	5.73	79.40%	6.37	40.64
Slovenya	8.13	10.74	10.15	9.81	12.17	15.1	20.08	10.24	8.24	11.82	10.59	10.13	11.79	13.66	12.91	121.29%	7.97	63.53
İspanya	41.5	39.07	47.6	44.09	54.46	44.41	46.05	42.5	22.82	42.96	32.6	23.4	22.02	25.9	35.66	33.87%	23.5	552.28
İsviçre	16.83	12.52	14.01	9.06	8.43	-0.94	-2.92	-0.87	-5	-1.55	-5.11	-2.66	-4.97	-8.63	-4.91	99.84%	19.44	377.81
Türkiye	83	101.62	75.71	72.85	78.3	82.39	109.47	105.1	116.15	114.85	172.8	149.42	162.38	177.13	153.48	840.58%	93.22	8689.38
BİRLEŞİK KRALLIK.	165.76	158.48	158.61	180.09	203.88	156.22	239.01	113.78	116.31	115.97	95.21	74.29	103.46	90.55	91.81	27.55%	65.62	4305.47
ABD	3624.9	3623.8	4004.8	4428.5	4294.6	4379.2	4376.9	4342.4	4377.7	4379.4	4464.1	4679.3	4646.1	4633.1	4970.4	30%	1025.7	1052075

Yüksek GTD Büyümesi: Japonya, Almanya ve Amerika Birleşik Devletleri yüksek mutlak değerler sergileyerek yeşil teknolojilerde önemli yatırım ve benimseme oranlarına işaret etmektedir.

İlmlı GTD Büyümesi: Avustralya, Kanada ve Meksika gibi ülkeler yıllar içinde GTD'de istikrarlı ancak ilmlı artışlar göstermiştir.

Düşük GTD Büyümesi: İrlanda, İzlanda, Avusturya, Çekya, Letonya, Litvanya, Norveç, Slovakya, Slovenya, İsviçre, İsrail, Kosta Rika ve Estonya gibi bazı ülkeler belirli yıllarda düşük ve hatta negatif değerler göstererek yeşil teknolojilerin benimsenmesinde potansiyel zorluklara işaret etmektedir.

Ayrıca Tablo 1, model geliştirme süreci boyunca belirlenen hata ölçümlemlerini ve doğruluk parametrelerini göstermektedir. MAPE tahminin doğruluğunu ölçer. Düşük MAPE değerleri daha yüksek doğruluğa işaret eder. Örneğin, Kanada (%17,96), Avustralya (%21,99) ve Almanya (%25,61) gibi ülkeler nispeten düşük MAPE değerlerine sahiptir ve bu da daha güvenilir tahminlere işaret etmektedir. Buna karşılık, Belçika (%974,68), Türkiye (%840,58) ve Kolombiya (%354,18) gibi ülkeler yüksek MAPE değerlerine sahiptir ve bu da daha az doğru tahminlere işaret etmektedir. RMSE artıklarının standart sapmasını vermektedir. Düşük değerler, tahminlerin gerçek veri noktalarına yakın olduğunu gösterir. İzlanda (1,3), Estonya (1,42) ve Litvanya (2,34) düşük RMSE değerlerine sahipken, Japonya (1740,8), ABD (%1125,7) ve Almanya (%253,38) önemli ölçüde yüksek RMSE değerlerine sahiptir ve bu da daha büyük tahmin hatalarına işaret eder. MSE hataların karelerinin ortalamasıdır. İrlanda (1,69), Estonya (2) ve Litvanya (5,49) gibi ülkeler daha düşük MSE değerlerine sahipken, Japonya (3030934), ABD (1052075) ve Almanya (64200,55) son derece yüksek MSE değerlerine sahiptir.

4.1. Tartışma

Çalışmanın bulguları Japonya, Almanya ve ABD'nin GTD'de önemli bir büyüme yaşayacağını göstermektedir. Bu bulgu, bu ülkelerin yeşil teknolojideki liderliğini vurgulayan son çalışmalarla tutarlıdır. Örneğin, Jaffe ve diğerleri (2003) tarafından yapılan bir çalışma, bu ülkelerdeki gelişmiş araştırma altyapısının ve agresif politika çerçevelerinin rolünün altını çizmektedir ve bu da yeşil teknolojinin benimsenmesinde güçlü bir büyüme gösteren sonuçlarımızla uyumludur. Ayrıca, Grubler ve diğerlerinin (1991) çalışması da bu gözlemi desteklemekte ve inovasyona önemli yatırımlar yapan ve destekleyici düzenleyici ortamlara sahip ülkelerin teknoloji yayılımında liderlik edebileceğini vurgulamaktadır.

Öte yandan, Avustralya, Kanada ve Meksika gibi ülkelerde yeşil teknolojilerin benimsenmesinde ilmlı artışlar görüleceği tahmin edilmektedir. Bu durum, Hascic ve diğerleri (2020) tarafından yapılan ve bu ülkelerin yeşil teknolojide önemli adımlar atmış olmalarına rağmen, ilerlemelerinin daha az agresif politika önlemleri ve önde gelen ülkelere kıyasla daha yavaş ekonomik geçişler nedeniyle engellendiğini ortaya koyan araştırma gibi son arařtırmalarla tutarlıdır. İrlanda ve İzlanda'nın yeşil teknolojinin benimsenmesinde düşük veya negatif büyüme ile zorluklarla karşılaşacağı tahmin edilmektedir. Bu durum, daha küçük veya ekonomik çeşitliliği daha az olan ülkelerin daha az yerleşik teknolojiler nedeniyle daha hızlı benimseme oranları yaşayabileceğini öne süren Zeng ve diğerleri (2022) gibi bazı yeni çalışmalardan farklılık göstermektedir. Sonuçlar, sınırlı ekonomik kaynaklar ve daha az agresif çevre politikaları gibi belirli engellerin bu ülkelerde daha yavaş veya durgun büyümeye katkıda bulunduğunu göstermektedir.

5. Sonuç ve Politika Çıkarımları

Bu çalışmada, 1980-2022 ve 2023-2037 yılları arasında OECD ülkelerinde yeşil teknolojilerin yayılımını tahmin etmek için ARIMA modeli başta olmak üzere gelişmiş makine öğrenimi metodolojilerini kullandık. Veri kümesi iki bölüme ayrılmıştır: 66'sı ilk eğitim aşaması için, kalan %34'ü ise test için ayrılmıştır. Bu çalışmanın sonuçları, 2023'ten 2037'ye kadar OECD ülkeleri için GTD tahminlerine genel bir bakış sunarak büyüme eğilimlerini ve doğruluk ölçütlerini vurgulamaktadır. Japonya, Almanya ve ABD gibi ülkelerin yüksek GTD büyümesi yaşaması beklenirken, Avustralya, Kanada ve Meksika ılımlı artışlar göstermektedir. Buna karşılık, İrlanda ve İzlanda gibi ülkeler düşük veya negatif GTD değerleriyle zorluklarla karşılaşmaktadır. Bu tahminlerin doğruluğu Ortalama Mutlak Yüzde Hata (MAPE), RMSE ve MSE gibi ölçütler kullanılarak değerlendirilmektedir. Düşük MAPE değerleri (örneğin Kanada %17,96) ve RMSE (örneğin İzlanda 1,3) daha güvenilir tahminlere işaret ederken, yüksek değerler (örneğin Belçika %974,68 MAPE ve Japonya 1740,8 RMSE) daha az doğru tahminlere işaret etmektedir.

ARIMA modeline dayalı ampirik bulgular, çoğu ülkenin GTD'de artış eğilimi gösterdiğini ve bunun da tahmin dönemi boyunca yeşil teknolojinin benimsenmesi için olumlu bir görünüme işaret ettiğini ortaya koymuştur. Bu bulgulara göre Avustralya, Belçika, Kanada, Çekya, Danimarka, Finlandiya, Yunanistan, Macaristan, Hollanda, İspanya ve Slovakya gibi ülkeler GTD'de istikrarlı bir artış eğilimi göstererek yeşil teknolojinin benimsenmesindeki istikrarlı ilerlemeyi yansıtmaktadır. Öte yandan, Meksika, Lüksemburg, Türkiye ve ABD gibi ülkeler GTD'de daha dik bir artış eğilimi sergileyerek, muhtemelen yakın zamandaki politika değişiklikleri veya yeşil teknolojilere yapılan yatırımların artması nedeniyle daha hızlı benimseme oranlarına işaret etmektedir. Buna karşılık, Avusturya, Fransa, Japonya, Almanya, Finlandiya, Norveç ve İsviçre gibi ülkeler GTD'de tutarlı bir düşüş eğilimi göstererek yeşil teknolojilerin benimsenmesindeki istikrarlı ilerlemeyi yansıtmaktadır. Bu ülkeler yeşil teknolojilerin erken benimseyicileri olmuş ve çevresel sürdürülebilirliği destekleyen sağlam çerçeveler ve politikalar oluşturmuşlardır.

Kolombiya, Şili, Kosta Rika, Estonya, İzlanda, İrlanda, İtalya, İsrail, Litvanya, Letonya, Yeni Zelanda ve Slovenya dahil olmak üzere çoğu ülke, ekonomik, politik, çevresel ve sosyal faktörler nedeniyle yeşil teknoloji benimseme oranlarında değişkenlik anlamına gelebilecek tahmini GTD'de dalgalanmalar göstermektedir. Bu dalgalanmalar çeşitli faktörlere bağlanabilir. Ekonomik olarak, bu ülkeler yeşil teknolojiler için finansmanı etkileyen bütçe kısıtlamaları veya değişen önceliklerle karşı karşıya kalabilir. Siyasi olarak, hükümet veya politika yönelimindeki değişiklikler, çevre girişimleri için tutarsız desteğe yol açabilir. Çevresel olarak, doğal kaynak mevcudiyeti ve çevresel zorluklar yeşil teknolojilerin benimsenme hızını etkiler. Sosyal açıdan, kamu bilinci, kültürel tutumlar ve toplumun yeni teknolojileri benimsemeye hazır olması değişkenlik gösterebilir ve bu da eşit olmayan benimseme oranlarına neden olabilir.

Son olarak, bulgular yeşil teknolojilerin çevresel sorunların ele alınmasında ve sürdürülebilir ekonomik büyümenin desteklenmesindeki kritik rolünü vurgulamaktadır. Bu çalışmadan elde edilen bilgiler, uzun vadeli sürdürülebilirlik hedeflerine ulaşmak için yeşil teknolojilere yönelik stratejik planlama ve yatırımın öneminin altını çizmektedir. OECD ülkelerindeki politika yapıcılar ve paydaşlar, ekonomik dayanıklılığı ve çevresel sürdürülebilirliği teşvik etmek için yeşil teknolojilerin geliştirilmesine ve uygulanmasına öncelik vermelidir.

Bu bulgulardan yola çıkan bu çalışma, bölgede çevresel sürdürülebilirliğin teşvik edilmesi ve sürdürülebilir kalkınma için belirlenen çevresel hedeflere ulaşılmasında hükümetlere ve politika yapıcılara yardımcı olacak politika önerileri sunmaktadır. Hükümetler şunları artırmalıdır

Sübvansiyonlar, hibeler ve düşük faizli krediler yoluyla mali destek saęlayarak yeřil teknolojilere yatırım yapmak, çevre dostu çözümlerin geliştirilmesini ve yaygınlaştırılmasını hızlandırmak. Daha katı emisyon standartlarının uygulanması, yenilenebilir enerji kullanımı için zorunluluklar ve uyumsuzluk için cezalar içeren düzenleyici çerçevelerin güçlendirilmesi esastır. Kamu-özel sektör ortaklıklarının teşvik edilmesi, ortak finansman projeleri, risk paylaşımı ve bilgi alışveriři platformları yoluyla yeřil teknolojinin yaygınlaştırılmasını artırabilir. İşgücünü yeřil işlere hazırlamak için eğitim ve öğretim girişimlerine yatırım yapmak önemlidir; bu da müfredatların gözden geçirilmesini ve mesleki eğitim verilmesini içerir. Elektrikli araçlar için vergi iadeleri, güneş panelleri için sübvansiyonlar ve yeřil teknolojiler hakkında farkındalık kampanyaları yoluyla tüketicilerin benimsemesi teşvik edilebilir. Küçük ve orta ölçekli işletmelerin (KOBİ'ler) mali yardım, teknik destek ve yeřil ürünler için pazar erişimi ile desteklenmesi, teknolojinin daha geniş çapta benimsenmesi için hayati önem taşımaktadır. Küresel anlaşmalar, ortak arařtırmalar ve çevre forumlarına katılım yoluyla uluslararası işbirliği ve bilgi paylaşımı kolektif ilerlemeyi teşvik eder. Politika etkinliğini değerlendirmek, net hedefler belirlemek, benimseme verilerini toplamak ve gelecek tahminleri için makine öğrenimi modellerini kullanmak için sağlam izleme ve değerlendirme mekanizmalarının kurulması sürekli iyileştirmeyi sağlayacaktır. Bu öneriler, OECD ülkelerinde GTD'yi geliştirerek sürdürülebilir ekonomik büyümeyi ve çevrenin korunmasını teşvik etmektedir.

Bu çalışmada ARIMA modeli kullanılmış olsa da, gelecekteki arařtırmalarda sonuçların sinir aęları, destek vektör makineleri ve topluluk yöntemleri gibi dięer makine öğrenimi modelleriyle birleştirilmesi ve karşılaştırılması düşünülmelidir. Bu, GTD eğilimlerinin daha sağlam ve incelikli bir şekilde anlaşılmasını saęlar. İkinci olarak, bu çalışmanın sonuçları, farklı ekonomik özellikleri nedeniyle Afrika veya Asya'daki gelişmekte olan ülkeler için geçerli olmayabilir. Bu nedenle, gelecekteki arařtırmalar bu bölgelerden veri setleri kullanmayı düşünmelidir. Üçüncü olarak, gelecekteki çalışmalar, çeşitli politika müdahalelerinin GTD üzerindeki potansiyel etkilerini değerlendirmek için politika simülasyonu ve senaryo analizini içerebilir. Politika yapıcılar, farklı düzenleyici, finansal ve sosyal senaryoları simüle ederek yeřil teknolojinin benimsenmesini hızlandırmak için en etkili stratejileri daha iyi anlayabilirler.

Bu çalışmanın bir sınırlaması, farklı ülkelerdeki verilerin mevcudiyeti ve kalitesindeki değişkenliktir. Bazı OECD ülkeleri için yeřil teknolojilerin benimsenmesine ilişkin kapsamlı veriler mevcutken, dięerleri eksik veya tutarsız verilere sahip olabilir. Bu sınırlama, tahmin modellerinin doğruluğunu ve güvenilirliğini etkileyebilir. ARIMA modelinin kullanımı, zaman serisi verilerinde doğrusallık ve duraęanlık gibi belirli varsayımlara dayanmaktadır. ARIMA tahmin için güçlü bir araç olsa da, bu varsayımlar GTD'nin karmaşık, doğrusal olmayan dinamiklerini tam olarak yakalayamayabilir.

Arařtırma ve Yayın Etięi Beyannamesi

Etik kurul onayı ve/veya yasal/özel izin gerektirmeyen bu çalışma arařtırma ve yayın etięine uygundur.

Arařtırmacı Katkı Oranı Beyanı

Yazarlar makaleye eşit katkıda bulunduklarını beyan etmişlerdir.

Arařtırmacının Çıkar Çatışması Beyanı

Bu çalışmada herhangi bir potansiyel çıkar çatışması bulunmamaktadır.

Referanslar

- Afshan, S., Yaqoob, T., Meo, M.S. ve Hamid, B. (2023). Yeşil finans, yeşil teknolojiler ve çevre politikalarının sıklığı Çin'de sürdürülebilirliği artırabilir mi? Kantil-ARDL tahmininden elde edilen kanıtlar. *Environmental Science and Pollution Research*, 30(22), 61726-61740. <https://doi.org/10.1007/s11356-023-26346-1>
- Ahmad, M., Kuldasheva, Z., Nasriddinov, F., Balbaa, M.E. ve Fahlevi, M. (2023). Çevresel sürdürülebilirliğin sağlanması bilgi iletişim teknolojisi ve küreselleşmeye mi bağlı? Seçilmiş OECD ülkelerinden kanıtlar. *Environmental Technology and Innovation*, 31, 103178. <https://doi.org/10.1016/j.eti.2023.103178>
- Allan, C., Jaffe, A.B. ve Sin, I. (2013). Yeşil teknolojinin yayılması: Bir araştırma. *International Review of Environmental and Resource Economics*, 7(1), 1-33. <https://doi.org/10.1561/101.00000055>
- Aminullah, E. (2024). Endonezya'da teknoloji inovasyonu ve ekonomik büyüme tahmini. *Teknolojik Tahmin ve Sosyal Değişir*, 202, 123333. <https://doi.org/10.1016/j.techfore.2024.123333>
- Bessi, A., Guidolin, M. ve Manfredi, P. (2021). Yenilenebilir enerji yayılımının gelecek perspektiflerinde gazın rolü: Teknoloji köprüsü mü yoksa kilitlenme mi? *Renewable and Sustainable Energy Reviews*, 152, 111673. <https://doi.org/10.1016/j.rser.2021.111673>
- Chen, L. ve Tanchangya, P. (2022). Çin'de yeşil büyüme üzerinde çevre teknolojilerinin ve çevre politikalarının sıklığının rolünün analizi. *Environmental Science and Pollution Research*, 29(37), 55630-55638. <https://doi.org/10.1007/s11356-022-19673-2>
- Chen, Y., Yao, Z. ve Zhong, K. (2022). Karbon emisyonları ve hava kirliliğine ilişkin çevresel düzenlemeler yeşil teknoloji inovasyonunu teşvik ediyor mu? Çin'in vilayet düzeyindeki şehirlerinden kanıtlar. *Journal of Cleaner Production*, 350, 131537. <https://doi.org/10.1016/J.JCLEPRO.2022.131537>
- Ciccarelli, M. ve Marotta, F. (2024). Talep mi arz mı? İklim değişikliğinin etkilerinin ampirik bir araştırması üzerinde ve makroekonomi. *Enerji Ekonomi*, 129, 107163. <https://doi.org/10.1016/j.eneco.2023.107163>
- Cohen, F., Glachant, M., Söderholm, P. ve Stephan, M. (2017). Enerji fiyatlarının yenilenebilir enerjinin benimsenmesi üzerindeki etkisi: Avrupa Birliği'nden Dersler. *Renewable Energy*, 105, 165-176. <https://doi.org/10.1016/j.eneco.2017.10.020>
- Dewick, P., Green, K., Fleetwood, T. ve Miozzo, M. (2006). Yaratıcı yıkımın modellenmesi: Teknolojik yayılım ve 2050'ye kadar endüstriyel yapı değişimi. *Technological Forecasting and Social Change*, 73(9), 1084-1106. <https://doi.org/10.1016/j.techfore.2006.04.002>
- Dutz, M.A. ve Sharma, S. (2012). *Yeşil büyüme, teknoloji ve inovasyon* (Politika Araştırma Çalışma Belgesi No. 5932). <https://core.ac.uk/download/pdf/6419675.pdf> adresinden alındı
- Grübler, A., Nakićenović, N. ve Victor, D.G. (1999). Teknolojik değişimin modellenmesi: Implications for the global environment. *Annual Review of Energy and the Environment*, 24(1), 545-569. <https://doi.org/10.1146/annurev.energy.24.1.545>
- Habiba, U., Xinbang, C. ve Anwar, A. (2022). Yeşil teknoloji yenilikleri, finansal gelişme ve yenilenebilir enerji kullanımı karbon emisyonlarını azaltmaya yardımcı olur mu? *Renewable Energy*, 193, 1082-1093. <https://doi.org/10.1016/J.RENENE.2022.05.084>
- Hall, B. H. (2004). İnovasyon ve yayılma. J. Fagerberg ve D.C. Mowery (der.), *The Oxford handbook of innovation* içinde (s. 459-484). <https://doi.org/10.1093/oxfordhb/9780199286805.003.0017>
- Hall, B. H. ve Khan, B. (2003). *Yeni teknolojilerin benimsenmesi* (NBRE Working Paper Series No. 9730). https://www.nber.org/system/files/working_papers/w9730/w9730.pdf adresinden alındı
- Han, C. ve Yang, L. (2024). Yeşil kalkınma projelerinin genişletilmesi için finansman ve yönetim stratejileri: Makine öğrenimi (ML) modellemesi kullanılarak Çin'in yenilenebilir enerji sektöründe enerji şirketi üzerine bir vaka çalışması. *Sustainability*, 16(11), 4338. <https://doi.org/10.3390/su16114338>

- Hao, L.N., Umar, M., Khan, Z. ve Ali, W. (2021). G7 ülkelerinde yeşil büyüme ve düşük karbon emisyonu: Çevre vergileri, yenilenebilir enerji ve beşeri sermaye ağı ne kadar kritik? *Science of the Total Environment*, 752, 141853. <https://doi.org/10.1016/j.scitotenv.2020.141853>
- Haščič, I., Johnstone, N., Watson, F. ve Kaminker, C. (2020). *İklim politikası ve teknolojik yenilik ve transfer: Eğilimlere ve son ampirik sonuçlara genel bir bakış* (OECD Çevre Çalışma Belgeleri No. 30). <https://doi.org/10.1787/5km33bnggcd0-en>
- Hübler, M. (2011). Daralma ve yakınsama altında teknoloji yayılımı: Çin üzerine bir CGE analizi. *Energy Economics*, 33(1), 131-142. <https://doi.org/10.1016/j.eneco.2010.09.002>
- Hussain, J., Lee, C.C. ve Chen, Y. (2022a). Yeşil tahvil ve sübvansiyon desteği altında emisyon üreten şirketlerde optimum yeşil teknoloji yatırımı ve emisyon azaltımı. *Technological Forecasting and Social Change*, 183, 121952. <https://doi.org/10.1016/j.techfore.2022.121952>
- Hussain, Z., Mehmood, B., Khan, M.K. ve Tsimisaraka, R.S.M. (2022b). Yeşil büyüme, yeşil teknoloji ve çevre sağlığı: Yüksek GSYİH'li ülkelerden kanıtlar. *Frontiers in Public Health*, 9, 816697. <https://doi.org/10.3389/fpubh.2021.816697>
- Jaffe, A.B., Newell, R.G. ve Stavins, R.N. (2003). Teknolojik değişim ve çevre. K-G içinde. Mäler ve J.R. Vincent (der.), *Handbook of environmental economics* (s. 461-516). [https://doi.org/10.1016/S1574-0099\(03\)01016-7](https://doi.org/10.1016/S1574-0099(03)01016-7)
- Johnstone, N., Haščič, I. ve Popp, D. (2010). Yenilenebilir enerji politikaları ve teknolojik yenilik: Patent sayılarına dayalı kanıtlar. *Environmental and Resource Economics*, 45(1), 133-155. <https://doi.org/10.1007/s10640-009-9309-1>
- Lee, J. ve Yang, J.S. (2018). Enerji sektöründe kamu Ar-Ge yatırım kararları: LCOE öngörü modeli, regresyon analizinin yapamadığını ortaya koyuyor. *Energy Strategy Reviews*, 21, 1-15. <https://doi.org/10.1016/j.esr.2018.04.003>
- Lin, B. ve Ma, R. (2022). Yeşil teknoloji yenilikleri, kentsel yenilik ortamı ve Çin'de CO2 emisyonunun azaltılması: Kısmen doğrusal fonksiyonel katsayı panel modelinden yeni kanıtlar. *Teknolojik Tahmin ve Sosyal Değişir*, 176, 121434. <https://doi.org/10.1016/J.TECHFORE.2021.121434>
- Luo, S. ve Mabrouk, F. (2022). Kaynak zengini ülkelerde doğal kaynaklar, küreselleşme ve ekolojik sürdürülebilirlik arasındaki bağlantı: Yeşil teknoloji ve çevresel düzenlemelerin dinamik rolü. *Resources Policy*, 79, 103027. <https://doi.org/10.1016/J.RESOURPOL.2022.103027>
- Luo, Z., Wang, C., Tang, Q. ve Tian, W. (2024). Yenilenebilir enerji teknolojisi inovasyonunun ekonomi büyümesi üzerindeki etkisi. *Chemistry and Technology of Fuels and Oils*, 59(6), 1271-1278. <https://doi.org/10.1007/s10553-024-01644-7>
- Lv, C., Shao, C. ve Lee, C.C. (2021). Yeşil teknoloji inovasyonu ve finansal kalkınma: Çevresel düzenleme ve inovasyon çıktısı önemli mi? *Enerji Ekonomisi*, 98, 105237. <https://doi.org/10.1016/j.eneco.2021.105237>
- Magazzino, C., Mele, M. ve Schneider, N. (2021). Güneş ve rüzgar enerjisi üretimi, kömür tüketimi, GSYİH ve CO2 emisyonları arasındaki ilişki üzerine bir makine öğrenimi yaklaşımı. *Renewable Energy*, 167, 99-115. <https://doi.org/10.1016/j.renene.2020.11.050>
- Magazzino, C., Mele, M., Morelli, G. ve Schneider, N. (2021). Bilgi teknolojisi ve çevre kirliliği arasındaki bağlantı: Yeni bir makine öğrenimi algoritmasının OECD ülkelerine uygulanması. *Utilities Policy*, 72, 101256. <https://doi.org/10.1016/j.jup.2021.101256>
- Maiti, M. (2022). Yeşil büyümedeki iyileşme çevreyle ilgili teknolojilerin gelişimini etkiliyor mu? *İnovasyon ve Yeşil Geliştirme*, 1(2), 100008. <https://doi.org/10.1016/j.igd.2022.100008>
- Meng, F., Xu, Y. ve Zhao, G. (2020). Çevresel düzenlemeler, yeşil inovasyon ve imalat işletmelerinin akıllı iyileştirilmesi: Çin'den Kanıtlar. *Scientific Reports*, 10(1), 14485. <https://doi.org/10.1038/s41598-020-71423-x>

- Nakano, S. ve Washizu, A. (2022). Yeni nesil enerji sisteminin analizi için girdi-çıkı tablosu kullanarak karbon fiyatlandırması için enerji vergisi reformu üzerine bir çalışma. *Energies*, 15, 2162. <https://doi.org/10.3390/en15062162>
- Oyebanji, M.O. ve Kirikkaleli, D. (2023). Batı Avrupa ülkelerinde yeşil teknoloji, yeşil elektrik ve çevresel sürdürülebilirlik. *Environmental Science and Pollution Research*, 30(13), 38525-38534. <https://doi.org/10.1007/s11356-022-24793-w>
- Peiró-Signes, Á., Segarra-Oña, M., Trull-Domínguez, Ó. ve Sánchez-Planelles, J. (2022). Şirketlerin ekoinovatif yönelimi için içsel-dışsal itici güçlerin ideal kombinasyonunun ortaya çıkarılması: Makine öğrenimi yöntemlerinden elde edilen sonuçlar. *Sosyo-Ekonomik Planlama Bilimleri*, 79, 101145. <https://doi.org/10.1016/j.seps.2021.101145>
- Popp, D. (2006). Uluslararası inovasyon ve hava kirliliği kontrol teknolojilerinin yayılması: ABD, Japonya ve Almanya'da NOX ve SO2 düzenlemelerinin etkileri. *Journal of Environmental Economics and Management*, 51(1), 46-71. <https://doi.org/10.1016/j.jeeem.2005.04.006>
- Rao, K.U. ve Kishore, V.V.N. (2010). Yenilenebilir enerji teknolojilerine özel referansla teknoloji yayılım modellerinin gözden geçirilmesi. *Renewable and Sustainable Energy Reviews*, 14(3), 1070-1078. <https://doi.org/10.1016/j.rser.2009.11.007>
- Rogers, E.M. (2003). *Yeniliklerin yayılması* (5. baskı). New York: Free Press.
- Sadiq, M., Chau, K.Y., Ha, N.T.T., Phan, T.T.H., Ngo, T.Q. ve Huy, P.Q. (2023). BRICS ülkelerinde yeşil finans, eko-inovasyon, yenilenebilir enerji ve karbon vergilerinin CO2 emisyonları üzerindeki etkisi: CS ARDL tahmininden elde edilen kanıtlar. *Geoscience Frontiers*, 101689. <https://doi.org/10.1016/J.GSF.2023.101689>
- Shahzad, M., Qu, Y., Rehman, S.U. ve Zafar, A.U. (2022). İmalat sanayinde sürdürülebilir kalkınmayı hızlandırmak için yeşil inovasyon teknolojisinin benimsenmesi. *Journal of Innovation and Knowledge*, 7(4), 100231. <https://doi.org/10.1016/j.jik.2022.100231>
- Shen, F., Liu, B., Luo, F., Wu, C., Chen, H. ve Wei, W. (2021). Ekonomik büyüme hedefi kısıtlamalarının yeşil teknoloji inovasyonu üzerindeki etkisi. *Journal of Environmental Management*, 292, 112765. <https://doi.org/10.1016/j.jenvman.2021.112765>
- Sun, Q., Chen, H., Wang, Y., Wang, X., Peng, X., Zhang, Q. ve Sun, Y. (2024). Çevresel karbon baskısı düşük karbonlu teknoloji inovasyonuna yol açar mı? Çin şehirlerinden uydu uzaktan algılama ve makine öğrenimine dayalı ampirik kanıtlar. *Computers and Industrial Engineering*, 189, 109948. <https://doi.org/10.1016/j.cie.2024.109948>
- Sun, Y., Li, H., Andlib, Z. ve Genie, M.G. (2022). Yenilenebilir enerji ve kentleşme karbon emisyonlarına nasıl neden oluyor? Gelişmiş panel tahmin tekniklerinden elde edilen kanıtlar. *Renewable Energy*, 185, 996-1005. <https://doi.org/10.1016/j.renene.2021.12.112>
- Tornatzky, L.G. ve Fleischer, M. (1990). *Teknolojik yenilik süreçleri*. Maryland: Lexington Books.
- Tsimisaraka, R.S.M., Xiang, L., Andrianarivo, A.R.N.A., Josoa, E.Z., Khan, N., Hanif, M.S., ... Limongi, R. (2023). OBOR ülkelerinde finansal katılım, küreselleşme, yenilenebilir enerji, ICT ve ekonomik büyümenin CO2 emisyonu üzerindeki etkisi. *Sustainability*, 15(8), 6534. <https://doi.org/10.3390/su15086534>
- Tuganova, R., Permyakova, A., Kuznetsova, A., Rakhmanova, K., Monzul, N., Uvarov, R., ... Budenny, S. (2022). Yeşil enerji teknolojileri için patentleme eğilimleri ve araştırma faaliyetleri arasındaki ilişkiler. *arXiv e-prints, arXiv-2010*. <http://arxiv.org/abs/2210.09611> .adresinden alındı
- UNFCCC. (2015). Paris Anlaşması. Birleşmiş Milletler iklim değişikliği çerçeve sözleşmesi. <https://unfccc.int/process-and-meetings/the-paris-agreement> .adresinden alındı
- Wang, Q., Sun, T. ve Li, R. (2023a). Yapay zeka yeşil inovasyonu teşvik ediyor mu? Doğrudan, dolaylı, yayılma ve heterojenlik etkilerine dayalı bir değerlendirme. *Energy & Environment*. <https://doi.org/10.1177/0958305x231220520>
- Wang, S., Zhang, W., Wang, H., Wang, J. ve Jiang, M.J. (2021). Gelir eşitsizliği yolsuzluk bağlamında çevresel düzenlemeleri nasıl etkiler? Çin'e dayalı bir panel eşik analizi

il verileri. *Uluslararası Çevre Arařtırmaları ve Halk Saėlıėı Dergisi*, 18(15), 8050.
<https://doi.org/10.3390/ijerph18158050>

- Wang, X., Li, J. ve Wang, N. (2023). Ekonomik büyüme baskıları yeřil toplam faktör verimliliėi artıřını engelliyor mu? *Sustainability*, 15(6), 5239. <https://doi.org/10.3390/su15065239>
- Xu, S.C., Li, Y.F., Zhang, J.N., Wang, Y., Ma, X.X., Liu, H.Y., ... Tao, Y. (2021). Doğrudan yabancı yatırım ve çevresel düzenlemeler yeřil teknoloji inovasyonunu geliştirir mi? Çin imalat sanayinden panel verilerine dayalı ampirik bir analiz. *Environmental Science and Pollution Research*, 28(39), 55302-55314. <https://doi.org/10.1007/s11356-021-14648-1>
- Zeng, S., Tanveer, A., Fu, X., Gu, Y. ve Irfan, M. (2022). Kritik faktörlerin yeřil enerji teknolojilerinin benimsenmesi üzerindeki etkisinin modellenmesi. *Renewable and Sustainable Energy Reviews*, 168, 112817. <https://doi.org/10.1016/j.rser.2022.112817>
- Zhang, D., Mohsin, M., Rasheed, A.K., Chang, Y. ve Taghizadeh-Hesary, F. (2021). BRI bölgesinde kamu harcamaları ve yeřil ekonomik büyüme: Yeřil finansın aracılık rolü. *Energy Policy*, 153(1), 112256. <https://doi.org/10.1016/j.enpol.2021.112256>
- Zhang, S., Bauer, N., Yin, G. ve Xie, X. (2020). Küresel ve yerel ölçeklerde teknoloji öğrenimi ve yayılımı: REMIND modelinde bir modelleme çalışması. *Technological Forecasting and Social Change*, 151, 119765. <https://doi.org/10.1016/j.techfore.2019.119765>
- Zhao, Q., Jiang, M., Zhao, Z., Liu, F. ve Zhou, L. (2024). Çin'de yeřil inovasyonun karbon azaltma verimliliėi üzerindeki etkisi: Makine öğrenimi doğrulamasından elde edilen kanıtlar. *Energy Economics*, 133, 107525. <https://doi.org/10.1016/j.eneco.2024.107525>
- Zhou, P., Abbas, J., Najam, H. ve Alvarez-Otero, S. (2023). Asya'nın geliřmekte olan ekonomilerinin karbon nötrlüėü için yenilenebilir enerji üretimi, yeřil teknolojik yenilik ve finansal geliřme bağlantısı. *Sustainable Energy Technologies and Assessments*, 58, 103371. <https://doi.org/10.1016/J.SETA.2023.103371>
- Zhou, W., Zhuang, Y. ve Chen, Y. (2024). Yapay zeka, enerji verimliliėini artırarak ve yeřil teknoloji geliştirerek kirletici emisyonlarını nasıl etkiler? *Energy Economics*, 131, 107355. <https://doi.org/10.1016/j.eneco.2024.107355>