



www.turkishstudies.net/economy

Turkish Studies - Economics, Finance, Politics

eISSN: 2667-5625

Research Article / Araştırma Makalesi



Classification of Greenhouse Gas Emission Levels in Turkey: An Integrated Assessment via LOO-CV and Causal Forest Analysis

Türkiye'nin Sera Gazı Emisyon Düzeyinin Sınıflandırılması: LOO-CV ve Nedensel Orman Analizi ile Bütünleşik Bir Değerlendirme

Burcu Kartal*

Abstract: This study examines the determinants of greenhouse gas emission levels using machine learning-based classification methods and annual data from Turkey for the period 1990–2024. Greenhouse gas emission values were used as the target variable in the study. To ensure a statistically balanced class distribution when categorizing the target variable, the median of the greenhouse gas emission series was adopted as the threshold value. Years below this threshold were labeled as low emissions (class 0), while those above were labeled as high emissions (class 1). In the study, the Gradient Boosting, Random Forest, and Logistic Regression algorithms were evaluated comparatively. Due to the small sample size, the leave-one-out cross-validation (LOO-CV) method was used for model evaluation. Model interpretability was ensured through SHAP (SHapley Additive exPlanations) analysis and causal forest analysis. According to the LOO-CV results, Random Forest, Logistic Regression, and Gradient Boosting delivered high-performance results. The SHAP analysis identified GDP as the primary determinant. The share of renewable energy, the share of fossil fuel consumption, and the trade deficit ranked second, third, and fourth, respectively. According to the results of the Causal Forest analysis, it can be stated that an increase in the share of renewable energy statistically significantly reduces emissions, while an increase in GDP statistically significantly increases emissions. The findings indicate that Turkey has permanently transitioned to a high-emission regime since 2007. This study makes four original contributions to the Turkish literature by reframing emission determinants as a classification problem defined around a statistically balanced threshold (median), providing reliable model evaluation using LOO-CV, offering interpretability through SHAP analysis, and performing causal inference beyond mere correlation using the Causal Forest method.

Keywords: Quantitative Methods, Greenhouse Gas Emissions, Machine Learning, Classification Analysis, Environmental Kuznets Curve, SHAP Analysis, Causal Forest.

Öz: Bu çalışma, Türkiye'nin 1990–2024 dönemine ait yıllık verilerini kullanarak sera gazı emisyonu düzeyinin belirleyicilerini makine öğrenmesi tabanlı sınıflandırma yöntemleri ile incelemektedir. Çalışmada sera gazı

* Asst. Prof. Dr., Recep Tayyip Erdogan University, Faculty of Economics and Administrative Sciences, Department of Business Administration

Dr. Öğr. Üyesi, Recep Tayyip Erdogan Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü

ORCID <https://orcid.org/0000-0001-8340-0234>

burcu.kartal@erdogan.edu.tr

Cite as/ Atıf: Kartal, B (2026). Classification of greenhouse gas emission levels in Turkey: An integrated assessment via LOO-CV and causal forest analysis / Türkiye'nin sera gazı emisyon düzeyinin sınıflandırılması: LOO-CV ve nedensel orman analizi ile bütünleşik bir değerlendirme. *Turkish Studies – Economics, Finance, Politics*, 21(Ö1), 1811-1875. [Special Issues Dedicated to Prof. Dr. Mahmut Özer], Ankara Bilim University Publications. <https://dx.doi.org/10.7827/TurkishStudies.90538>

Received/Geliş: 13 April/Nisan 2026

Accepted/Kabul: 15 September/Eylül 2026

Published/Yayın: 20 September/Eylül 2026

Checked by plagiarism software



emisy n deęerleri hedef deęiřken olarak kullanılmıřtır. Hedef deęiřkenin kategorik hale getirilmesinde istatistiksel a ıdan dengeli bir sınıf daęılımı saęlamak amacıyla sera gazı emisyon serisinin medyanı eřik deęer olarak benimsenmiřtir. Bu eřięin altındaki yıllar d ř k emisyon (sınıf 0),  zerindekiler y ksek emisyon (sınıf 1) sınıfı olarak etiketlenmiřtir.  alıřmada, Gradient Boosting, Random Forest ve Lojistik Regresyon algoritmaları karřılařtırmalı olarak deęerlendirilmiřtir. K   k  rneklem durumu nedeniyle model deęerlendirmesinde bırak-bir-dıřarıda  apraz doęrulama (LOO-CV) y ntemi kullanılmıřtır. Model yorumlanabilirlięi SHAP (SHapley Additive exPlanations) analizi ve nedensel orman analizi ile saęlanmıřtır. LOO-CV sonu larına g re Random Forest, Lojistik Regresyon ve Gradient Boosting y ksek performanslı sonu lar sunmuřlardır. SHAP analizi GSY H'yı birincil belirleyici olarak tespit etmiřtir. Yenilenebilir enerji payı, fosil yakıt t ketimi payı ve dıř ticaret a ıklıęı ise sırasıyla ikinci,    nc  ve d rd nc  sırada yer almıřtır. Nedensel Orman analizi sonu larına g re, yenilenebilir enerji payındaki artıřın istatistiksel olarak anlamlı bi imde emisyonu azalttıęı ve GSY H'daki artıřın emisyonu anlamlı bi imde y kselttięi s ylenebilir. Bulgular T rkiye'nin 2007 yılından itibaren y ksek emisyon rejimine kalıcı bi imde ge tięini g stermektedir.  alıřma; emisyon belirleyicilerini istatistiksel a ıdan dengeli bir eřik (medyan) etrafında tanımlanmıř sınıflandırma problemi olarak yeniden  er evelemesi, LOO-CV ile g venilir model deęerlendirmesi saęlaması, SHAP analizi ile yorumlanabilirlik sunması ve Nedensel Orman y ntemiyle korelasyonun  tesinde nedensel  ıkarım ger ekleřtirmesiyle T rkiye yazınına d rt  zg n katkı sunmaktadır.

Anahtar Kelimeler: Nicel Y ntemler, Sera Gazı Emisyonu, Makine  ęrenmesi, Sınıflandırma Analizi,  evresel Kuznets Eęrisi, SHAP Analizi, Nedensel Orman.

Structured Abstract:

Climate change has taken its place in the literature as one of the most comprehensive and critical global environmental problems of the twenty-first century. At the heart of policy discussions aimed at combating this global crisis is the systematic reduction of greenhouse gas emissions, primarily carbon dioxide (CO_2). Environmental pressures, particularly those stemming from fossil fuel consumption, further deepen the historical tension between economic growth targets and ecological sustainability, making the analysis of emission determinants both a scientific and political necessity. The Paris Agreement, signed in 2015, has directed signatory countries to set concrete reduction targets through national contribution declarations and to develop measurable tools to achieve these targets. Turkey, while under pressure from rapid economic growth, urbanization, and industrialization, is simultaneously trying to strike a unique balance between increasing its renewable energy capacity and reducing its dependence on energy imports. Türkiye's greenhouse gas emissions, which were 229 million tons in 1990, have increased significantly to 584 million tons by 2024. While much of the existing literature treats emissions as a continuous variable, the crucial question for policymakers is whether emissions exceed defined strategic thresholds. This study aims to fill this gap by reframing Türkiye's emission level as a binary classification problem defined around the median of the greenhouse gas series (395.9 Mt). The main objective of the study is to examine the factors distinguishing between high and low emission regimes using machine learning algorithms with data from the 1990-2024 period, and to support the obtained results with SHAP analysis and Causal Forest analysis.

The theoretical basis of this study rests on the Environmental Kuznets Curve (EKC) hypothesis, which predicts an inverted U-shaped relationship between per capita income and environmental pollution. According to the hypothesis, economic growth initially increases pollution, but after a certain income threshold, it reduces emissions thanks to technological transformation. In the Turkish literature, this hypothesis has been tested using traditional econometric methods by authors such as Halicioğlu (2009), Katircioğlu (2014), and Pata (2018). However, most of these studies rely on linear assumptions and do not fully reflect structural heterogeneity. In terms of the energy mix, the emission-increasing effect of fossil fuels and the mitigating potential of renewable energy are among the main axes of discussion. In addition, trade openness is considered within the framework of the pollution haven hypothesis, in the context of the transfer of polluting industries to countries with lower standards. In recent years, the application of machine learning methods to emission prediction has provided an advantage, especially in capturing complex nonlinear relationships. A literature review revealed a lack of studies in Turkish literature that focus on the classification problem, systematically report model interpretability using SHAP values, and make causal inferences beyond correlation. This study offers a theoretical and methodological contribution by integrating Causal Forest analysis and shifting the focus from "what is related?" to "what can be intervened in?".

This study analyzes Turkey's emission dynamics for the period 1990–2024 using Turkish Statistical Institute (TUIK) and World Bank data within a machine learning framework. To improve the model's explainability, GDP per capita, fossil fuel share, renewable energy share, and trade deficit were determined as baseline variables; highly correlated structural variables were excluded to prevent data leakage. Continuous emission data were converted into two balanced classes with a median threshold value (395.9 Mt), thus framing the problem within a classification framework. Gradient Boosting, Random Forest, and Logistic Regression algorithms were applied comparatively in the analysis; hyperparameter optimization was performed using 5-fold cross-validation. Due to the limited sample size ($n=35$), the Leave-One-Out Cross-Validation (LOO-CV) method was preferred to minimize prediction bias. To overcome the "black box" nature of the models, game theory-based SHAP analysis was used, and causal inferences between variables were conducted via Causal Forest using the Dual Machine Learning (DML) approach.

This study offers original contributions to the literature by analyzing Turkey's emission dynamics using machine learning and causal inference methods. In the classification analysis, Random Forest and Logistic Regression models demonstrated the highest predictive performance, achieving an $F1=0.973$ score with the LOO-CV method. These results are methodologically consistent with the studies by Rufaioğlu et al. (2025) and Bakır et al. (2022), which highlight the success of ensemble learning algorithms in modeling Turkey's emission structure. The SHAP analysis shows that the primary factor determining the emission regime is GDP, followed by the share of renewable energy. This finding is consistent with the studies by Katircioğlu (2014) and Pata (2018), which support the validity of the Environmental Kuznets Curve hypothesis for Turkey. Causal Forest analysis has shown that renewable energy reduces emissions by an average of 47,501 Mt, while

openness to foreign trade has a significant enhancing effect (ATE: 23.623 Mt). The causal significance of foreign trade indicates that the pollution haven hypothesis operates as a secondary channel in Turkey, adding a unique perspective to Cole's (2004) literature. The integrated use of SHAP and Causal Forest methods clarifies both the discriminatory power of the variables and the net results of the interventions, offering a scientific roadmap against Türkiye's high emission regime that has become permanent since 2007.

This study offers a unique contribution to the literature by modeling Turkey's emission dynamics using advanced data analytics methods. The main policy recommendation developed based on the analysis results is to prioritize renewable energy capacity, whose emission-reducing effects have been scientifically proven. In this process, removing bureaucratic obstacles to solar and wind investments, phasing out coal power plants, and implementing market-based mechanisms such as carbon pricing are critically important. The main limitation of the study is the small sample size ($n=35$). Therefore, it is recommended that future research delve deeper into specific sectors and be conducted using deep learning algorithms over longer time series to obtain a more precise analysis of the impact of energy transition on the emission regime.

Keywords: Quantitative Methods, Greenhouse Gas Emissions, Machine Learning, Classification Analysis, Environmental Kuznets Curve, SHAP Analysis, Causal Forest

ملخص منظم:

احتل تغير المناخ مكانته في الأدبيات باعتباره إحدى أكثر المشكلات البيئية العالمية شمولاً وأهمية في القرن الحادي والعشرين. ويقع في صميم المناقشات السياسية الهادفة إلى مكافحة هذه الأزمة العالمية التخفيض المنهجي لانبعاثات غازات الدفيئة، وفي مقدمتها ثاني أكسيد الكربون (CO₂). وتؤدي الضغوط البيئية، لا سيما تلك الناجمة عن استهلاك الوقود الأحفوري، إلى تعميق التوتر التاريخي بين أهداف النمو الاقتصادي والاستدامة البيئية، مما يجعل تحليل العوامل المحددة للانبعاثات ضرورة علمية وسياسية على حد سواء. وقد وجهت اتفاقية باريس، الموقعة في عام 2015، الدول الموقعة إلى تحديد أهداف خفض ملموسة من خلال إعلانات المساهمات الوطنية، وتطوير أدوات قابلة للقياس لتحقيق هذه الأهداف. وتسعى تركيا، رغم تعرضها لضغوط ناجمة عن النمو الاقتصادي السريع والتحضر والتصنيع، في الوقت نفسه إلى تحقيق توازن فريد بين زيادة طاقتها من الطاقة المتجددة وتقليل اعتمادها على واردات الطاقة. وقد ارتفعت انبعاثات غازات الدفيئة في تركيا، التي بلغت 229 مليون طن في عام 1990، بشكل ملحوظ لتصل إلى 584 مليون طن بحلول عام 2024. وفي حين أن معظم الدراسات الحالية تتعامل مع الانبعاثات باعتبارها متغيراً مستمراً، فإن السؤال الحاسم الذي يواجه صانعي السياسات هو ما إذا كانت الانبعاثات تتجاوز العتبات الاستراتيجية المحددة تهدف هذه الدراسة إلى سد هذه الفجوة من خلال إعادة صياغة مستوى انبعاثات تركيا باعتباره مشكلة تصنيف ثنائية تُحدد حول الوسيط لسلسلة غازات الدفيئة (395.9 مليون طن). ويتمثل الهدف الرئيسي للدراسة في فحص العوامل التي تميز بين أنظمة الانبعاثات العالية والمنخفضة وتحليل الغابة السببية SHAP باستخدام خوارزميات التعلم الآلي مع بيانات من الفترة 1990-2024، ودعم النتائج التي تم التوصل إليها بتحليل

مقارب بين U التي تتنبأ بعلاقة على شكل حرف E (EKC) ويستند الأساس النظري لهذه الدراسة إلى فرضية منحني كوزنيس البيئي الدخلى الفردي والتلوث البيئي. ووفقاً لهذه الفرضية، يؤدي النمو الاقتصادي في البداية إلى زيادة التلوث، ولكنه بعد تجاوز عتبة دخل معينة، يقلل الانبعاثات بفضل التحول التكنولوجي. وفي الأدبيات التركية، تم اختبار هذه الفرضية باستخدام الأساليب الاقتصادية القياسية التقليدية من قبل باحثين ومع ذلك، تعتمد معظم هذه الدراسات على افتراضات خطية ولا (Pata (2018)، و Katırcıoğlu (2014)، و Halicioğlu (2009) مثل تعكس بشكل كامل التباين الهيكلي. وفيما يتعلق بمزيج الطاقة، يُعد تأثير الوقود الأحفوري في زيادة الانبعاثات وإمكانية الطاقة المتجددة في التخفيف من حدة التلوث من بين المحاور الرئيسية للنقاش. بالإضافة إلى ذلك، يُنظر إلى انفتاح التجارة في إطار فرضية «ملاذ التلوث»، في سياق نقل الصناعات الملوثة إلى بلدان ذات معايير أقل. وفي السنوات الأخيرة، وفر تطبيق أساليب التعلم الآلي على التنبؤ بالانبعاثات ميزة، لا سيما في استيعاب العلاقات غير الخطية المعقدة. كشفت مراجعة الأدبيات عن نقص في الدراسات التركية التي تركز على مشكلة التصنيف وتستخلص استنتاجات سببية تتجاوز مجرد الارتباط. تقدم هذه الدراسة، SHAP، وتقدم تقارير منهجية حول قابلية تفسير النموذج باستخدام قيم وتحويل التركيز من «ما الذي يرتبط؟» إلى «ما الذي يمكن (Causal Forest) (مساهمة نظرية ومنهجية من خلال دمج تحليل «الغابة السببية» التداخل فيه؟

والبنك (TUİK) تحلل هذه الدراسة ديناميكيات الانبعاثات في تركيا للفترة 1990-2024 باستخدام بيانات المعهد التركي للإحصاء الدولي ضمن إطار التعلم الآلي. ولتحسين قابلية تفسير النموذج، تم تحديد الناتج المحلي الإجمالي للفرد، وحصة الوقود الأحفوري، وحصة الطاقة المتجددة، والعجز التجاري كمتغيرات أساسية؛ وتم استبعاد المتغيرات الهيكلية ذات الارتباط العالي لمنع تسرب البيانات. تم تحويل بيانات الانبعاثات المستمرة إلى فئتين متوازنتين بقيمة عتبة متوسطة (395.9 مليون طن)، وبذلك تم وضع المشكلة ضمن إطار التصنيف. تم تطبيق Logistic (Logistic) «و» الانحدار اللوجستي (Random Forest) «و» الغابة العشوائية (Gradient Boosting) «خوارزميات» التعزيز التدريجي بشكل مقارن في التحليل؛ وتم إجراء تحسين المعلمة الفائقة باستخدام التحقق المتقاطع الخماسي. ونظراً لمحدودية حجم العينة (n=35) لتقليل انحياز التنبؤ إلى أدنى حد. وللتغلب على طبيعة (Leave-One-Out) (LOO-CV) تم تقصير طريقة التحقق المتقاطع (n=35) Causal القائم على نظرية الألعاب، وأجريت الاستدلالات السببية بين المتغيرات عبر SHAP الصندوق الأسود» للنماذج، تم استخدام تحليل» (DML) باستخدام نهج التعلم الآلي المزودج Forest).

تقدم هذه الدراسة مساهمات أصلية في الأدبيات من خلال تحليل ديناميكيات الانبعاثات في تركيا باستخدام التعلم الآلي وأساليب Logistic (Logistic) «و» الانحدار اللوجستي (Random Forest) «الاستدلال السببي. في تحليل التصنيف، أظهرت نماذج «الغابة العشوائية

تتوافق هذه النتائج من الناحية المنهجية مع LOO-CV باستخدام طريقة $F1=0.973$ أعلى أداء تنبؤي، حيث حققنا درجة (Regression) الدراسات التي أجراها روفايو غلو وآخرون (2025) وباكير وآخرون (2022)، والتي تسلط الضوء على نجاح خوارزميات التعلم الجماعي في أن العامل الرئيسي الذي يحدد نظام الانبعاثات هو الناتج المحلي الإجمالي، يليه نصيب SHAP نمذجة هيكل الانبعاثات في تركيا. ويظهر تحليل الطاقة المتجددة. ويتوافق هذا الاستنتاج مع الدراسات التي أجراها كاتيرجيو غلو (2014) وباتا (2018)، والتي تدعم صحة فرضية منحني Mt أن الطاقة المتجددة تقلل الانبعاثات بمعدل (Causal Forest) 47,501 «كوزنتس البيئي بالنسبة لتركيا. وقد أظهر تحليل «الغابة السببية» وتشير الأهمية السببية للتجارة الخارجية إلى أن فرضية (ATE: 23.623 Mt) في حين أن الانفتاح على التجارة الخارجية له تأثير معزز كبير ملاذ التلوث» تعمل كقناة ثانوية في تركيا، مما يضيف منظوراً فريداً إلى الأدبيات التي قدمها كول (2004). ويوضح الاستخدام المتكامل» و«الغابة السببية» كلاً من القدرة التمييزية للمتغيرات والناتج الصافي للتدخلات، مما يوفر خارطة طريق علمية لمواجهة SHAP لطريقتي نظام الانبعاثات المرتفعة في تركيا الذي أصبح دائماً منذ عام 2007

تقدم هذه الدراسة مساهمة فريدة في الأدبيات من خلال نمذجة ديناميكيات الانبعاثات في تركيا باستخدام أساليب متقدمة لتحليل البيانات وتمثل التوصية السياسية الرئيسية التي تم تطويرها بناءً على نتائج التحليل في إعطاء الأولوية لطاقة مصادر الطاقة المتجددة، التي ثبت علمياً تأثيرها في خفض الانبعاثات. وفي هذه العملية، تكتسب إزالة العقبات البيروقراطية التي تعترض استثمارات الطاقة الشمسية وطاقة الرياح والتخلص التدريجي من محطات توليد الطاقة بالفحم، وتنفيذ الآليات قائمة على السوق مثل تسعير الكربون، أهمية بالغة. يمثل القيد الرئيسي ولذلك، يُوصى بأن تتعمق الأبحاث المستقبلية في قطاعات محددة، وأن تُجرى باستخدام خوارزميات (n=35) للدراسة في صغر حجم العينة. التعلم العميق على سلاسل زمنية أطول للحصول على تحليل أكثر دقة لتأثير التحول في قطاع الطاقة على نظام الانبعاثات

SHAP، الكلمات المفتاحية: الأساليب الكمية، انبعاثات غازات الدفيئة، التعلم الآلي، تحليل التصنيف، منحني كوزنتس البيئي، تحليل الغابة السببية

Résumé Structuré:

Le changement climatique s'est imposé dans la littérature comme l'un des problèmes environnementaux mondiaux les plus vastes et les plus critiques du XXI^e siècle. Au cœur des débats politiques visant à lutter contre cette crise mondiale se trouve la réduction systématique des émissions de gaz à effet de serre, principalement le dioxyde de carbone (CO_2). Les pressions environnementales, en particulier celles découlant de la consommation de combustibles fossiles, accentuent encore la tension historique entre les objectifs de croissance économique et la durabilité écologique, faisant de l'analyse des déterminants des émissions une nécessité à la fois scientifique et politique. L'Accord de Paris, signé en 2015, a chargé les pays signataires de fixer des objectifs de réduction concrets par le biais de déclarations de contributions nationales et de mettre au point des outils mesurables pour atteindre ces objectifs. La Turquie, bien que soumise à la pression d'une croissance économique rapide, de l'urbanisation et de l'industrialisation, s'efforce simultanément de trouver un équilibre unique entre l'augmentation de sa capacité en énergies renouvelables et la réduction de sa dépendance vis-à-vis des importations d'énergie. Les émissions de gaz à effet de serre de la Turquie, qui s'élevaient à 229 millions de tonnes en 1990, ont considérablement augmenté pour atteindre 584 millions de tonnes en 2024. Alors qu'une grande partie de la littérature existante traite les émissions comme une variable continue, la question cruciale pour les décideurs politiques est de savoir si les émissions dépassent des seuils stratégiques définis. La présente étude vise à combler cette lacune en recadrant le niveau d'émissions de la Turquie comme un problème de classification binaire défini autour de la médiane de la série des gaz à effet de serre (395,9 Mt). L'objectif principal de l'étude est d'examiner les facteurs distinguant les régimes à fortes émissions de ceux à faibles émissions à l'aide d'algorithmes d'apprentissage automatique sur des données couvrant la période 1990-2024, et d'étayer les résultats obtenus par une analyse SHAP et une analyse par forêt causale.

Le fondement théorique de cette étude repose sur l'hypothèse de la courbe de Kuznets environnementale (EKC), qui prédit une relation en U inversé entre le revenu par habitant et la pollution environnementale. Selon cette hypothèse, la croissance économique accroît dans un premier temps la pollution, mais au-delà d'un certain seuil de revenu, elle réduit les émissions grâce à la transformation technologique. Dans la littérature turque, cette hypothèse a été testée à l'aide de méthodes économétriques traditionnelles par des auteurs tels que Halicioğlu (2009), Katircioğlu (2014) et Pata (2018). Cependant, la plupart de ces études reposent sur des hypothèses linéaires et ne reflètent pas pleinement l'hétérogénéité structurelle. En ce qui concerne le mix énergétique, l'effet d'augmentation des émissions lié aux combustibles fossiles et le potentiel d'atténuation des énergies renouvelables figurent parmi les principaux axes de discussion. De plus, l'ouverture commerciale est prise en compte dans le cadre de l'hypothèse du « refuge de pollution », dans le contexte du transfert des industries polluantes vers des pays aux normes moins strictes. Ces dernières années, l'application de méthodes d'apprentissage automatique à la prévision des émissions a apporté un avantage, notamment pour saisir des relations non linéaires complexes. Une revue de la littérature a révélé un manque d'études dans la

littérature turque qui se concentrent sur le problème de classification, rendent compte de manière systématique de l'interprétabilité des modèles à l'aide des valeurs SHAP et établissent des inférences causales allant au-delà de la simple corrélation. La présente étude apporte une contribution théorique et méthodologique en intégrant l'analyse « Causal Forest » et en déplaçant l'accent de la question « qu'est-ce qui est lié ? » vers « sur quoi peut-on intervenir ? ».

Cette étude analyse la dynamique des émissions de la Turquie pour la période 1990-2024 à l'aide des données de l'Institut turc de statistique (TUIK) et de la Banque mondiale, dans un cadre d'apprentissage automatique. Afin d'améliorer l'explicabilité du modèle, le PIB par habitant, la part des combustibles fossiles, la part des énergies renouvelables et le déficit commercial ont été retenus comme variables de référence ; les variables structurelles fortement corrélées ont été exclues pour éviter toute fuite de données. Les données d'émissions continues ont été converties en deux classes équilibrées à l'aide d'une valeur seuil médiane (395,9 Mt), ce qui a permis d'inscrire le problème dans un cadre de classification. Les algorithmes de « gradient boosting », de « forêt aléatoire » et de régression logistique ont été appliqués de manière comparative dans l'analyse ; l'optimisation des hyperparamètres a été réalisée à l'aide d'une validation croisée en 5 plis. En raison de la taille limitée de l'échantillon ($n = 35$), la méthode de validation croisée « Leave-One-Out » (LOO-CV) a été privilégiée afin de minimiser le biais de prédiction. Pour pallier la nature de « boîte noire » des modèles, une analyse SHAP fondée sur la théorie des jeux a été utilisée, et des inférences causales entre les variables ont été menées via Causal Forest à l'aide de l'approche Dual Machine Learning (DML).

Cette étude apporte des contributions originales à la littérature en analysant la dynamique des émissions de la Turquie à l'aide de méthodes d'apprentissage automatique et d'inférence causale. Dans l'analyse de classification, les modèles « Random Forest » et de régression logistique ont démontré les meilleures performances prédictives, atteignant un score $F1 = 0,973$ avec la méthode LOO-CV. Ces résultats sont méthodologiquement cohérents avec les études de Rufaioglu et al. (2025) et de Bakır et al. (2022), qui soulignent le succès des algorithmes d'apprentissage en ensemble dans la modélisation de la structure des émissions de la Turquie. L'analyse SHAP montre que le principal facteur déterminant le régime d'émissions est le PIB, suivi de la part des énergies renouvelables. Ce constat est cohérent avec les études de Katircioglu (2014) et de Pata (2018), qui confirment la validité de l'hypothèse de la courbe de Kuznets environnementale pour la Turquie. L'analyse par la méthode Causal Forest a montré que les énergies renouvelables réduisent les émissions de 47 501 Mt en moyenne, tandis que l'ouverture au commerce extérieur a un effet amplificateur significatif (ATE : 23,623 Mt). La signification causale du commerce extérieur indique que l'hypothèse du « refuge de pollution » opère comme un canal secondaire en Turquie, apportant ainsi une perspective unique à la littérature de Cole (2004). L'utilisation intégrée des méthodes SHAP et Causal Forest clarifie à la fois le pouvoir discriminant des variables et les résultats nets des interventions, offrant ainsi une feuille de route scientifique pour lutter contre le régime d'émissions élevées de la Turquie, devenu permanent depuis 2007.

Cette étude apporte une contribution unique à la littérature en modélisant la dynamique des émissions de la Turquie à l'aide de méthodes avancées d'analyse des données. La principale recommandation politique formulée sur la base des résultats de l'analyse consiste à donner la priorité aux capacités en énergies renouvelables, dont les effets de réduction des émissions ont été scientifiquement prouvés. Dans ce processus, il est essentiel de lever les obstacles bureaucratiques aux investissements dans le solaire et l'éolien, de supprimer progressivement les centrales à charbon et de mettre en œuvre des mécanismes fondés sur le marché, tels que la tarification du carbone. La principale limite de cette étude réside dans la petite taille de l'échantillon ($n = 35$). Il est donc recommandé que les recherches futures approfondissent l'étude de secteurs spécifiques et soient menées à l'aide d'algorithmes d'apprentissage profond sur des séries chronologiques plus longues afin d'obtenir une analyse plus précise de l'impact de la transition énergétique sur le régime d'émissions.

Mots-clés: Méthodes quantitatives, Émissions de gaz à effet de serre, Apprentissage automatique, Analyse de classification, Courbe de Kuznets environnementale, Analyse SHAP, Forêt causale

Resumen Estructurado:

El cambio climático se ha consolidado en la literatura como uno de los problemas medioambientales globales más amplios y críticos del siglo XXI. En el centro de los debates políticos destinados a combatir esta crisis global se encuentra la reducción sistemática de las emisiones de gases de efecto invernadero, principalmente el dióxido de carbono (CO_2). Las presiones medioambientales, en particular las derivadas del

consumo de combustibles fósiles, agravan aún más la tensión histórica entre los objetivos de crecimiento económico y la sostenibilidad ecológica, lo que convierte el análisis de los factores determinantes de las emisiones en una necesidad tanto científica como política. El Acuerdo de París, firmado en 2015, ha instado a los países signatarios a establecer objetivos concretos de reducción a través de las declaraciones de contribuciones nacionales y a desarrollar herramientas cuantificables para alcanzar dichos objetivos. Turquía, aunque se ve sometida a la presión del rápido crecimiento económico, la urbanización y la industrialización, intenta al mismo tiempo lograr un equilibrio único entre el aumento de su capacidad de energía renovable y la reducción de su dependencia de las importaciones energéticas. Las emisiones de gases de efecto invernadero de Turquía, que en 1990 ascendían a 229 millones de toneladas, han aumentado significativamente hasta alcanzar los 584 millones de toneladas en 2024. Si bien gran parte de la bibliografía existente trata las emisiones como una variable continua, la cuestión crucial para los responsables políticos es si las emisiones superan los umbrales estratégicos definidos. El presente estudio pretende colmar esta laguna replanteando el nivel de emisiones de Turquía como un problema de clasificación binaria definido en torno a la mediana de la serie de gases de efecto invernadero (395,9 Mt). El objetivo principal del estudio es examinar los factores que distinguen entre regímenes de altas y bajas emisiones utilizando algoritmos de aprendizaje automático con datos del período 1990-2024, y respaldar los resultados obtenidos con análisis SHAP y análisis de «Causal Forest».

La base teórica de este estudio se asienta en la hipótesis de la Curva de Kuznets Ambiental (EKC), que predice una relación en forma de U invertida entre la renta per cápita y la contaminación ambiental. Según esta hipótesis, el crecimiento económico aumenta inicialmente la contaminación, pero, tras superar un determinado umbral de renta, reduce las emisiones gracias a la transformación tecnológica. En la literatura turca, esta hipótesis ha sido puesta a prueba mediante métodos econométricos tradicionales por autores como Halicioğlu (2009), Katircioğlu (2014) y Pata (2018). Sin embargo, la mayoría de estos estudios se basan en supuestos lineales y no reflejan plenamente la heterogeneidad estructural. En cuanto a la combinación energética, el efecto de aumento de las emisiones de los combustibles fósiles y el potencial mitigador de las energías renovables se encuentran entre los principales ejes de debate. Además, la apertura comercial se considera en el marco de la hipótesis del «refugio de la contaminación», en el contexto del traslado de industrias contaminantes a países con normas menos estrictas. En los últimos años, la aplicación de métodos de aprendizaje automático a la predicción de emisiones ha supuesto una ventaja, especialmente a la hora de captar relaciones no lineales complejas. Una revisión bibliográfica reveló una falta de estudios en la literatura turca que se centren en el problema de la clasificación, informen sistemáticamente sobre la interpretabilidad de los modelos utilizando valores SHAP y realicen inferencias causales más allá de la correlación. Este estudio ofrece una contribución teórica y metodológica al integrar el análisis de «Causal Forest» y desplazar el enfoque de «¿qué está relacionado?» a «¿en qué se puede intervenir?».

Este estudio analiza la dinámica de las emisiones de Turquía para el período 1990-2024 utilizando datos del Instituto Turco de Estadística (TUIK) y del Banco Mundial dentro de un marco de aprendizaje automático. Para mejorar la explicabilidad del modelo, se determinaron como variables de referencia el PIB per cápita, la cuota de combustibles fósiles, la cuota de energías renovables y el déficit comercial; se excluyeron las variables estructurales altamente correlacionadas para evitar la fuga de datos. Los datos continuos de emisiones se convirtieron en dos clases equilibradas con un valor umbral mediano (395,9 Mt), enmarcando así el problema en un marco de clasificación. En el análisis se aplicaron de forma comparativa los algoritmos de Gradient Boosting, Random Forest y regresión logística; la optimización de los hiperparámetros se llevó a cabo mediante validación cruzada de 5 pliegues. Debido al tamaño limitado de la muestra ($n = 35$), se optó por el método de validación cruzada «Leave-One-Out» (LOO-CV) para minimizar el sesgo de predicción. Para superar la naturaleza de «caja negra» de los modelos, se utilizó el análisis SHAP basado en la teoría de juegos, y las inferencias causales entre variables se llevaron a cabo mediante Causal Forest utilizando el enfoque de aprendizaje automático dual (DML).

Este estudio ofrece aportaciones originales a la literatura al analizar la dinámica de las emisiones de Turquía mediante métodos de aprendizaje automático e inferencia causal. En el análisis de clasificación, los modelos Random Forest y de regresión logística demostraron el mayor rendimiento predictivo, alcanzando una puntuación $F1 = 0,973$ con el método LOO-CV. Estos resultados son metodológicamente coherentes con los estudios de Rufaioğlu et al. (2025) y Bakır et al. (2022), que destacan el éxito de los algoritmos de aprendizaje conjunto a la hora de modelar la estructura de las emisiones de Turquía. El análisis SHAP muestra que el principal factor que determina el régimen de emisiones es el PIB, seguido de la cuota de energías renovables.

Este hallazgo concuerda con los estudios de Katircioğlu (2014) y Pata (2018), que respaldan la validez de la hipótesis de la curva de Kuznets medioambiental para Turquía. El análisis de Causal Forest ha demostrado que las energías renovables reducen las emisiones en una media de 47 501 Mt, mientras que la apertura al comercio exterior tiene un efecto potenciador significativo (ATE: 23,623 Mt). La significación causal del comercio exterior indica que la hipótesis del «refugio de contaminación» actúa como un canal secundario en Turquía, lo que aporta una perspectiva única a la bibliografía de Cole (2004). El uso integrado de los métodos SHAP y «Causal Forest» aclara tanto el poder discriminatorio de las variables como los resultados netos de las intervenciones, ofreciendo una hoja de ruta científica contra el régimen de altas emisiones de Turquía, que se ha consolidado desde 2007.

Este estudio ofrece una contribución única a la literatura al modelar la dinámica de las emisiones de Turquía utilizando métodos avanzados de análisis de datos. La principal recomendación de política desarrollada a partir de los resultados del análisis es dar prioridad a la capacidad de energía renovable, cuyos efectos de reducción de emisiones han sido demostrados científicamente. En este proceso, resulta de vital importancia eliminar los obstáculos burocráticos a las inversiones en energía solar y eólica, retirar progresivamente las centrales térmicas de carbón e implementar mecanismos basados en el mercado, como la fijación de precios del carbono. La principal limitación del estudio es el reducido tamaño de la muestra ($n = 35$). Por lo tanto, se recomienda que las investigaciones futuras profundicen en sectores específicos y se lleven a cabo utilizando algoritmos de aprendizaje profundo sobre series temporales más largas, con el fin de obtener un análisis más preciso del impacto de la transición energética en el régimen de emisiones.

Palabras clave: Métodos cuantitativos, Emisiones de gases de efecto invernadero, Aprendizaje automático, Análisis de clasificación, Curva de Kuznets medioambiental, Análisis SHAP, Bosque causal

结构化摘要:

气候变化已在学术文献中确立其地位, 被视为二十一世纪最全面、最严峻的全球环境问题之一。旨在应对这一全球危机的政策讨论的核心, 在于系统性地减少温室气体排放, 尤其是二氧化碳 (CO₂)。环境压力——尤其是源于化石燃料消耗的压力——进一步加剧了经济增长目标与生态可持续性之间的历史性矛盾, 使得对排放决定因素的分析既成为科学上的必要, 也是政治上的必要。2015年签署的《巴黎协定》要求缔约国通过国家自主贡献声明设定具体的减排目标, 并制定可衡量的工具以实现这些目标。土耳其在面临快速经济增长、城市化和工业化的压力的同时, 也在努力在扩大可再生能源产能与减少对能源进口的依赖之间寻求独特的平衡。土耳其的温室气体排放量从1990年的2.29亿吨显著增加至2024年的5.84亿吨。尽管现有文献大多将排放量视为连续变量, 但对政策制定者而言, 关键在于排放量是否超过了既定的战略阈值。本研究旨在填补这一空白, 将土耳其的排放水平重新定义为以温室气体数据序列中位数 (3.959亿吨) 为基准的二元分类问题。研究的主要目标是利用1990-2024年的数据, 通过机器学习算法考察区分高排放与低排放模式的因素, 并借助SHAP分析和因果森林分析来验证所得结果。

本研究的理论基础源于环境库兹涅茨曲线 (EKC) 假说, 该假说预测人均收入与环境污染之间存在倒U型关系。根据该假说, 经济增长初期会加剧污染, 但在达到一定收入阈值后, 得益于技术转型, 排放量将随之减少。在土耳其的学术文献中, Halicioğlu (2009)、Katircioğlu (2014) 和Pata (2018) 等学者曾采用传统的计量经济学方法对这一假说进行了检验。然而, 这些研究大多基于线性假设, 未能充分反映结构异质性。在能源结构方面, 化石燃料的增排效应以及可再生能源的减排潜力是主要讨论焦点。此外, 在“污染避风港假说”框架下, 贸易开放程度也被纳入考量, 其背景是污染产业向标准较低的国家转移。近年来, 机器学习方法在排放预测中的应用展现出显著优势, 尤其在捕捉复杂的非线性关系方面。文献综述表明, 土耳其学术界目前缺乏专注于分类问题、系统性地利用SHAP值报告模型可解释性, 并超越相关性进行因果推断的研究。本研究通过整合因果森林 (Causal Forest) 分析, 并将研究重点从“什么相关?”转向“什么可以干预?”, 在理论和方法论上做出了贡献。

本研究利用土耳其统计局 (TUIK) 和世界银行的数据, 在机器学习框架下分析了1990-2024年期间土耳其的排放动态。为提高模型的可解释性, 将人均GDP、化石燃料占比、可再生能源占比

和贸易逆差确定为基线变量；同时排除了高度相关的结构变量，以防止数据泄漏。连续的排放数据通过中位数阈值（395.9 Mt）被转换为两个平衡类，从而将问题纳入分类框架。分析中对比应用了梯度提升、随机森林和逻辑回归算法；并采用5折交叉验证法进行了超参数优化。由于样本量有限（ $n=35$ ），为最大限度地减少预测偏差，优先采用了“留一交叉验证”（LOO-CV）方法。为克服模型的“黑箱”特性，采用了基于博弈论的SHAP分析，并通过采用双重机器学习（DML）方法的因果森林（Causal Forest）对变量之间的因果关系进行了推断。

本研究通过运用机器学习和因果推断方法分析土耳其的排放动态，为相关文献做出了原创性贡献。在分类分析中，随机森林和逻辑回归模型展现出最高的预测性能，采用LOO-CV方法时F1值达到0.973。从方法论上看，这些结果与 Rufaioğlu 等（2025）和 Bakır 等（2022）的研究一致，这些研究突显了集成学习算法在建模土耳其排放结构方面的成功。SHAP 分析表明，决定排放模式的主要因素是 GDP，其次是可再生能源的占比。这一发现与 Katırcıoğlu（2014）和 Pata（2018）的研究结果一致，这些研究支持了“环境库兹涅茨曲线”假说在土耳其的适用性。因果森林分析表明，可再生能源平均可减少47,501 Mt的排放，而对外贸易开放度则具有显著的增强效应（ATE：23.623 Mt）。对外贸易的因果显著性表明，“污染避风港”假说在土耳其发挥着次要渠道的作用，这为科尔（2004）的相关文献提供了独特视角。SHAP与因果森林方法的综合应用，既阐明了各变量的区分能力，也揭示了干预措施的净效果，为应对土耳其自2007年以来已呈固化态势的高排放模式提供了科学路线图。

本研究通过运用先进的数据分析方法对土耳其的排放动态进行建模，为相关文献做出了独特贡献。基于分析结果提出的主要政策建议是优先发展可再生能源产能，其减排效果已得到科学验证。在此过程中，消除太阳能和风能投资面临的官僚障碍、逐步淘汰燃煤电厂以及实施碳定价等市场化机制至关重要。本研究的主要局限在于样本量较小（ $n=35$ ）。因此，建议未来研究深入探讨具体行业，并利用深度学习算法对更长的时序数据进行分析，以更精确地评估能源转型对排放模式的影响。

关键词：定量方法、温室气体排放、机器学习、分类分析、环境库兹涅茨曲线、SHAP分析、因果森林

Структурированное Резюме:

Изменение климата заняло в научной литературе место одной из наиболее всеобъемлющих и острых глобальных экологических проблем XXI века. В центре политических дискуссий, направленных на борьбу с этим глобальным кризисом, находится систематическое сокращение выбросов парниковых газов, в первую очередь углекислого газа (CO_2). Экологическая нагрузка, особенно связанная с потреблением ископаемого топлива, еще больше усугубляет историческое противоречие между целями экономического роста и экологической устойчивостью, что делает анализ факторов, определяющих выбросы, необходимостью как с научной, так и с политической точки зрения. Парижское соглашение, подписанное в 2015 году, обязывает страны-участницы устанавливать конкретные цели по сокращению выбросов посредством заявлений о национальных вкладах и разрабатывать измеримые инструменты для достижения этих целей. Турция, находясь под давлением быстрого экономического роста, урбанизации и индустриализации, одновременно пытается найти уникальный баланс между увеличением мощностей возобновляемых источников энергии и сокращением зависимости от импорта энергоресурсов. Выбросы парниковых газов в Турции, которые в 1990 году составляли 229 млн тонн, к 2024 году значительно выросли до 584 млн тонн. Хотя в большей части существующей литературы выбросы рассматриваются как непрерывная переменная, ключевым вопросом для политиков является то, превышают ли выбросы установленные стратегические пороговые значения. Данное исследование призвано восполнить этот пробел путем переформулирования уровня выбросов Турции в виде задачи бинарной классификации, определяемой относительно медианы ряда данных по парниковым газам (395,9 млн т). Основная цель исследования заключается в изучении факторов, отличающих режимы с высоким и низким уровнем выбросов, с использованием алгоритмов машинного обучения на данных за период 1990–2024 гг., а также в

подтверждении полученных результатов с помощью анализа SHAP и анализа «причинного леса» (Causal Forest).

Теоретическая основа данного исследования опирается на гипотезу экологической кривой Кузнеця (ЕКС), которая предсказывает обратно-U-образную зависимость между доходом на душу населения и загрязнением окружающей среды. Согласно этой гипотезе, экономический рост сначала приводит к увеличению загрязнения, но после достижения определенного порога дохода он способствует сокращению выбросов благодаря технологической трансформации. В турецкой литературе эта гипотеза проверялась с использованием традиционных эконометрических методов такими авторами, как Халичоглу (2009), Катырчоглу (2014) и Пата (2018). Однако большинство этих исследований основано на линейных допущениях и не в полной мере отражает структурную гетерогенность. Что касается структуры энергобаланса, то среди основных тем обсуждения фигурируют как эффект увеличения выбросов, связанный с использованием ископаемого топлива, так и потенциал возобновляемых источников энергии по снижению выбросов. Кроме того, в рамках гипотезы «убежища от загрязнения» рассматривается открытость торговли в контексте перемещения загрязняющих отраслей в страны с более низкими стандартами. В последние годы применение методов машинного обучения для прогнозирования выбросов дало определенные преимущества, особенно в плане учета сложных нелинейных взаимосвязей. Обзор литературы выявил недостаток исследований в турецкой научной литературе, которые бы фокусировались на задаче классификации, систематически отражали интерпретируемость моделей с использованием значений SHAP и делали причинно-следственные выводы, выходящие за рамки корреляции. Настоящее исследование вносит теоретический и методологический вклад за счет интеграции анализа «Causal Forest» и переноса акцента с вопроса «что связано?» на вопрос «на что можно повлиять?».

В данном исследовании анализируется динамика выбросов в Турции за период 1990–2024 гг. с использованием данных Турецкого статистического института (TUIK) и Всемирного банка в рамках машинного обучения. Для повышения объясняемости модели в качестве базовых переменных были определены ВВП на душу населения, доля ископаемого топлива, доля возобновляемых источников энергии и торговый дефицит; сильно коррелирующие структурные переменные были исключены для предотвращения утечки данных. Непрерывные данные о выбросах были преобразованы в два сбалансированных класса с медианным пороговым значением (395,9 млн т), что позволило сформулировать задачу в рамках классификационной модели. В ходе анализа были сравнительно применены алгоритмы градиентного бустинга, случайного леса и логистической регрессии; оптимизация гиперпараметров проводилась с использованием 5-кратной перекрестной валидации. В связи с ограниченным размером выборки ($n = 35$) для минимизации смещения прогнозов был выбран метод перекрестной валидации «Leave-One-Out» (LOO-CV). Для преодоления «чернокоробочного» характера моделей был использован SHAP-анализ, основанный на теории игр, а причинно-следственные связи между переменными были выявлены с помощью Causal Forest на основе подхода Dual Machine Learning (DML).

Данное исследование вносит оригинальный вклад в научную литературу благодаря анализу динамики выбросов в Турции с использованием методов машинного обучения и причинно-следственных выводов. В классификационном анализе модели «Случайный лес» (Random Forest) и логистической регрессии продемонстрировали наивысшую прогностическую эффективность, достигнув показателя $F1 = 0,973$ при использовании метода LOO-CV. Эти результаты методологически согласуются с исследованиями Руфайоглу и др. (2025) и Бакира и др. (2022), в которых подчеркивается успешность алгоритмов ансамблевого обучения при моделировании структуры выбросов в Турции. Анализ SHAP показывает, что основным фактором, определяющим режим выбросов, является ВВП, за которым следует доля возобновляемых источников энергии. Этот вывод согласуется с исследованиями Каырджоглу (2014) и Пата (2018), которые подтверждают обоснованность гипотезы «экологической кривой Кузнеця» для Турции. Анализ с использованием Causal Forest показал, что возобновляемые источники энергии сокращают выбросы в среднем на 47 501 Мт, в то время как открытость для внешней торговли оказывает значительный усиливающий эффект (ATE: 23,623 Мт). Причинная значимость внешней торговли указывает на то, что гипотеза «убежища от загрязнения» действует в Турции в качестве вторичного канала, что добавляет уникальную перспективу к исследованиям Коула (2004). Комплексное использование методов SHAP и «причинного леса» проясняет как дискриминационную

संक्षेपः
 способность переменных, так и чистые результаты вмешательств, предлагая научную дорожную карту для борьбы с режимом высоких выбросов в Турции, который стал постоянным с 2007 года.

Данное исследование вносит уникальный вклад в научную литературу, моделируя динамику выбросов в Турции с использованием передовых методов анализа данных. Основная политическая рекомендация, разработанная на основе результатов анализа, заключается в приоритетном развитии мощностей возобновляемых источников энергии, эффект снижения выбросов от которых научно доказан. В этом процессе критически важно устранить бюрократические препятствия для инвестиций в солнечную и ветровую энергетику, постепенно выводить из эксплуатации угольные электростанции и внедрять рыночные механизмы, такие как ценообразование на углерод. Основным ограничением исследования является небольшой размер выборки ($n=35$). Поэтому рекомендуется, чтобы будущие исследования более глубоко изучали конкретные секторы и проводились с использованием алгоритмов глубокого обучения на более длительных временных рядах для получения более точного анализа влияния энергетического перехода на режим выбросов.

Ключевые слова: количественные методы, выбросы парниковых газов, машинное обучение, классификационный анализ, экологическая кривая Кузнеца, SHAP-анализ, причинно-следственный лес

संरचित सारांशः

जलवायु परिवर्तन ने एकविंशतितम सदी की सबसे व्यापक और महत्वपूर्ण वैश्विक पर्यावरणीय समस्याओं में से एक के रूप में साहित्य में अपनी जगह बना ली है। इस वैश्विक संकट से निपटने के उद्देश्य से नीतिगत चर्चाओं के केंद्र में हरितगृह गैस उत्सर्जन, मुख्य रूप से कार्बन डाइऑक्साइड (CO_2), में व्यवस्थित कमी है। पर्यावरणीय दबाव, विशेष रूप से जीवाश्म ईंधन की खपत से उत्पन्न होने वाले दबाव, आर्थिक विकास के लक्ष्यों और पारिस्थितिक स्थिरता के बीच ऐतिहासिक तनाव को और गहरा करते हैं, जिससे उत्सर्जन निर्धारकों का विश्लेषण एक वैज्ञानिक और राजनीतिक दोनों तरह की आवश्यकता बन जाता है।

2015 में हस्ताक्षरित पेरिस समझौते ने हस्ताक्षरकर्ता देशों को राष्ट्रीय योगदान घोषणाओं के माध्यम से ठोस कमी लक्ष्य निर्धारित करने और इन लक्ष्यों को प्राप्त करने के लिए मापने योग्य उपकरण विकसित करने का निर्देश दिया है। तुर्की, तीव्र आर्थिक विकास, शहरीकरण और औद्योगिकीकरण के दबाव में रहते हुए, एक ही समय में अपनी नवीकरणीय ऊर्जा क्षमता बढ़ाने और ऊर्जा आयात पर अपनी निर्भरता कम करने के बीच एक अनूठा संतुलन बनाने का प्रयास कर रहा है। तुर्की के ग्रीनहाउस गैस उत्सर्जन, जो 1990 में 229 मिलियन टन थे, 2024 तक बढ़कर 584 मिलियन टन हो गए हैं। हालांकि मौजूदा साहित्य का अधिकांश भाग उत्सर्जन को एक निरंतर चर के रूप में मानता है, नीति निर्माताओं के लिए महत्वपूर्ण प्रश्न यह है कि क्या उत्सर्जन परिभाषित रणनीतिक सीमाओं से अधिक है। यह अध्ययन ग्रीनहाउस गैस श्रृंखला (395.9 Mt) के माधिका के आसपास परिभाषित, तुर्की के उत्सर्जन स्तर को एक द्विआधारी वर्गीकरण समस्या के रूप में पुनः निर्धारित करके इस अंतर को पाटने का लक्ष्य रखता है। इस अध्ययन का मुख्य उद्देश्य 1990-2024 की अवधि के डेटा के साथ मशीन लर्निंग एल्गोरिदम का उपयोग करके उच्च और निम्न उत्सर्जन व्यवस्थाओं के बीच अंतर करने वाले कारकों की जांच करना है, और प्राप्त परिणामों का SHAP विश्लेषण और Causal Forest विश्लेषण के साथ समर्थन करना है।

इस अध्ययन का सैद्धांतिक आधार पर्यावरणीय कुज़नेत्स वक्र (EKC) परिकल्पना पर आधारित है, जो प्रति व्यक्ति आय और पर्यावरणीय प्रदूषण के बीच एक उल्टे U-आकार के संबंध की भविष्यवाणी करती है। परिकल्पना के अनुसार, आर्थिक विकास शुरू में प्रदूषण बढ़ाता है, लेकिन एक निश्चित आय सीमा के बाद, यह तकनीकी परिवर्तन के कारण उत्सर्जन को कम कर देता है। तुर्की के साहित्य में, इस परिकल्पना का परीक्षण हालिसियोग्लू (2009), कटिरचियोग्लू (2014), और पाटा (2018) जैसे लेखकों द्वारा पारंपरिक अर्थमिति विधियों का उपयोग करके किया गया है। हालांकि, इनमें से अधिकांश अध्ययन रैखिक मान्यताओं पर निर्भर करते हैं और संरचनात्मक विषमता को पूरी तरह से प्रतिबिंबित नहीं करते हैं। ऊर्जा मिश्रण के संदर्भ में, जीवाश्म ईंधन के उत्सर्जन-बढ़ाने वाले प्रभाव और नवीकरणीय ऊर्जा की शमन क्षमता चर्चा के मुख्य विषयों में से हैं। इसके अतिरिक्त, प्रदूषण हेवन परिकल्पना के ढांचे के भीतर, प्रदूषण फैलाने वाले उद्योगों के निम्न मानकों वाले देशों में स्थानांतरण के संदर्भ में व्यापार खुलेपन पर भी विचार किया जाता है। हाल के वर्षों में, उत्सर्जन पूर्वानुमान के लिए मशीन लर्निंग विधियों के अनुप्रयोग ने एक लाभ प्रदान किया है, विशेष रूप से जटिल गैर-रेखीय संबंधों को समझने में। साहित्य समीक्षा से तुर्की के साहित्य में उन अध्ययनों की कमी का पता चला है जो वर्गीकरण समस्या पर ध्यान केंद्रित करते हैं, SHAP मानों का उपयोग करके व्यवस्थित रूप से मॉडल की व्याख्याक्षमता की रिपोर्ट करते हैं, और सहसंबंध से परे कारणगत निष्कर्ष निकालते हैं। यह अध्ययन Causal Forest विश्लेषण को एकीकृत करके और "क्या

संबंधित है?" से "क्या हस्तक्षेप किया जा सकता है?" पर ध्यान केंद्रित करके एक सैद्धांतिक और पद्धतिगत योगदान प्रदान करता है।

यह अध्ययन मशीन लर्निंग ढांचे के भीतर तुर्की सांख्यिकी संस्थान (TUIK) और विश्व बैंक के डेटा का उपयोग करके 1990–2024 की अवधि के लिए तुर्की की उत्सर्जन गतिशीलता का विश्लेषण करता है। मॉडल की व्याख्यात्मकता में सुधार करने के लिए, प्रति व्यक्ति जीडीपी, जीवाश्म ईंधन की हिस्सेदारी, नवीकरणीय ऊर्जा की हिस्सेदारी और व्यापार घाटे को आधारभूत चरों के रूप में निर्धारित किया गया; डेटा लीकेज को रोकने के लिए अत्यधिक सहसंबद्ध संरचनात्मक चरों को बाहर रखा गया। निरंतर उत्सर्जन डेटा को एक माधिका थ्रेशोल्ड मान (395.9 Mt) के साथ दो संतुलित वर्गों में परिवर्तित किया गया, इस प्रकार समस्या को एक वर्गीकरण ढांचे के भीतर रखा गया। विश्लेषण में ग्रेडिएंट बूस्टिंग, रैंडम फ़ॉरेस्ट और लॉजिस्टिक रिग्रेशन एल्गोरिदम की तुलनात्मक रूप से उपयोग किया गया; हाइपरपैरामीटर अनुकूलन 5-फ़ोल्ड क्रॉस-वैलिडेशन का उपयोग करके किया गया।

सीमित नमूना आकार ($n=35$) के कारण, भविष्यवाणी पक्षपात को कम करने के लिए लीव-वन-आउट क्रॉस-वैलिडेशन (LOO-CV) विधि को प्राथमिकता दी गई। मॉडलों की "ब्लैक बॉक्स" प्रकृति को दूर करने के लिए, गेम थ्योरी-आधारित SHAP विश्लेषण का उपयोग किया गया, और डुअल मशीन लर्निंग (DML) दृष्टिकोण का उपयोग करके कॉज़ल फ़ॉरेस्ट के माध्यम से चरों के बीच कारण संबंधी निष्कर्ष निकाले गए।

यह अध्ययन मशीन लर्निंग और कारणात्मक अनुमान विधियों का उपयोग करके तुर्की की उत्सर्जन गतिशीलता का विश्लेषण करके साहित्य में मौलिक योगदान प्रदान करता है। वर्गीकरण विश्लेषण में, रैंडम फ़ॉरेस्ट और लॉजिस्टिक रिग्रेशन मॉडल ने LOO-CV विधि के साथ $F1=0.973$ स्कोर प्राप्त करते हुए, सबसे उच्च भविष्यवाणी प्रदर्शन प्रदर्शित किया। ये परिणाम Rufaioğlu et al. (2025) और Bakır et al. (2022) के अध्ययनों के साथ पद्धतिगत रूप से सुसंगत हैं, जो तुर्की की उत्सर्जन संरचना के मॉडलिंग में एन्सेम्बल लर्निंग एल्गोरिदम की सफलता को उजागर करते हैं। SHAP विश्लेषण से पता चलता है कि उत्सर्जन शासन को निर्धारित करने वाला प्राथमिक कारक GDP है, जिसके बाद नवीकरणीय ऊर्जा का हिस्सा आता है। यह निष्कर्ष कटिचयोगलू (2014) और पाटा (2018) के अध्ययनों के अनुरूप है, जो तुर्की के लिए पर्यावरणीय कुज़नेत्स वक्र परिकल्पना की वैधता का समर्थन करते हैं। कारणात्मक वन विश्लेषण से पता चला है कि नवीकरणीय ऊर्जा उत्सर्जन को औसतन 47,501 मीट्रिक टन तक कम करती है, जबकि विदेशी व्यापार के प्रति खुलापन एक महत्वपूर्ण वृद्धि प्रभाव (ATE: 23.623 मीट्रिक टन) डालता है। विदेशी व्यापार का कारणात्मक महत्व यह दर्शाता है कि प्रदूषण हेवन परिकल्पना तुर्की में एक द्वितीयक चैनल के रूप में कार्य करती है, जो कोल (2004) के साहित्य में एक अनूठा दृष्टिकोण जोड़ता है। SHAP और कॉज़ल फ़ॉरेस्ट विधियों के एकीकृत उपयोग से चरों की विभेदक शक्ति और हस्तक्षेपों के शुद्ध परिणाम दोनों स्पष्ट होते हैं, जो 2007 से स्थायी रूप से स्थापित तुर्की के उच्च उत्सर्जन शासन के खिलाफ एक वैज्ञानिक रोडमैप प्रदान करता है।

यह अध्ययन उन्नत डेटा एनालिटिक्स विधियों का उपयोग करके तुर्की की उत्सर्जन गतिशीलता का मॉडलिंग करके साहित्य में एक अनूठा योगदान देता है। विश्लेषण के परिणामों के आधार पर विकसित मुख्य नीति सिफारिश नवीकरणीय ऊर्जा क्षमता को प्राथमिकता देना है, जिसके उत्सर्जन-घटाने वाले प्रभाव वैज्ञानिक रूप से सिद्ध हो चुके हैं। इस प्रक्रिया में, सौर और पवन निवेशों के लिए नौकरशाही बाधाओं को दूर करना, कोयला बिजली संयंत्रों को चरणबद्ध रूप से बंद करना, और कार्बन मूल्य निर्धारण जैसे बाजार-आधारित तंत्रों को लागू करना अत्यंत महत्वपूर्ण है।

अध्ययन की मुख्य सीमा नमूना आकार का छोटा होना ($n=35$) है। इसलिए, यह अनुशंसा की जाती है कि भविष्य के शोध में विशिष्ट क्षेत्रों में और गहराई से जाएँ और ऊर्जा संक्रमण के उत्सर्जन व्यवस्था पर प्रभाव का अधिक सटीक विश्लेषण प्राप्त करने के लिए लंबी समय श्रृंखलाओं पर डीप लर्निंग एल्गोरिदम का उपयोग करके इसे किया जाए।

कीवर्ड: मात्रात्मक विधियाँ, ग्रीनहाउस गैस उत्सर्जन, मशीन लर्निंग, वर्गीकरण विश्लेषण, पर्यावरणीय कुज़नेत्स वक्र, SHAP विश्लेषण, कारणात्मक वन

Yapılandırılmış Özet:

İklim değişikliği, yirmi birinci yüzyılın en kapsamlı ve kritik küresel çevre sorunlarından biri olarak literatürde yerini almıştır. Bu küresel krizle mücadele için amaçlayan politika tartışmalarının merkezinde, başta karbondioksit (CO_2) olmak üzere sera gazı emisyonlarının sistematik olarak azaltılması yer almaktadır. Çevresel baskılar, özellikle de fosil yakıt tüketiminden kaynaklananlar, ekonomik büyüme hedefleri ile ekolojik sürdürülebilirlik arasındaki tarihsel gerilimi daha da derinleştirerek, emisyon belirleyicilerinin

analizini hem bilimsel hem de siyasi bir zorunluluk haline getirmektedir. 2015 yılında imzalanan Paris Anlaşması, imzacı ülkeleri ulusal katkı beyanları yoluyla somut azaltım hedefleri belirlemeye ve bu hedeflere ulaşmak için ölçülebilir araçlar geliştirmeye yöneltmiştir. Türkiye, hızlı ekonomik büyüme, kentleşme ve sanayileşmenin yarattığı baskı altında olmakla birlikte, aynı zamanda yenilenebilir enerji kapasitesini artırmak ile enerji ithalatına bağımlılığını azaltmak arasında kendine özgü bir denge kurmaya çalışmaktadır. 1990 yılında 229 milyon ton olan Türkiye'nin sera gazı emisyonları, 2024 yılına kadar 584 milyon tona önemli ölçüde artmıştır. Mevcut literatürün büyük bir kısmı emisyonları sürekli bir değişken olarak ele alırken, politika yapımcılar için asıl önemli soru, emisyonların tanımlanmış stratejik eşik değerleri aşp aşmadığıdır. Bu çalışma, Türkiye'nin emisyon seviyesini sera gazı serisinin medyan değeri (395,9 Mt) etrafında tanımlanan ikili bir sınıflandırma problemi olarak yeniden çerçevelendirerek bu boşluğu doldurmayı amaçlamaktadır. Çalışmanın temel amacı, 1990-2024 dönemine ait verilerle makine öğrenimi algoritmaları kullanarak yüksek ve düşük emisyon rejimlerini birbirinden ayıran faktörleri incelemek ve elde edilen sonuçları SHAP analizi ve Nedensel Orman analizi ile desteklemektir.

Bu çalışmanın teorik temeli, kişi başına gelir ile çevre kirliliği arasında ters U şeklinde bir ilişki öngören Çevresel Kuznets Eğrisi (EKC) hipotezine dayanmaktadır. Hipoteze göre, ekonomik büyüme başlangıçta kirliliği artırır, ancak belirli bir gelir eşiğinin aşılmasından sonra teknolojik dönüşüm sayesinde emisyonları azaltır. Türk literatüründe bu hipotez, Halicioğlu (2009), Katırcıoğlu (2014) ve Pata (2018) gibi yazarlar tarafından geleneksel ekonometrik yöntemler kullanılarak test edilmiştir. Ancak bu çalışmaların çoğu doğrusal varsayımlara dayanmakta ve yapısal heterojenliği tam olarak yansıtmamaktadır. Enerji karışımı açısından, fosil yakıtların emisyon artırıcı etkisi ve yenilenebilir enerjinin azaltıcı potansiyeli tartışmanın ana eksenleri arasındadır. Ayrıca, kirlilik cenneti hipotezi çerçevesinde, kirlitici sanayilerin standartları daha düşük ülkelere taşınması bağlamında ticaretin açıklığı da ele alınmaktadır. Son yıllarda, emisyon tahminine makine öğrenimi yöntemlerinin uygulanması, özellikle karmaşık doğrusal olmayan ilişkilerin yakalanmasında bir avantaj sağlamıştır. Literatür taraması, Türk literatüründe sınıflandırma sorununa odaklanan, SHAP değerlerini kullanarak modelin yorumlanabilirliğini sistematik olarak raporlayan ve korelasyonun ötesinde nedensel çıkarımlarda bulunan çalışmaların eksikliğini ortaya koymuştur. Bu çalışma, Nedensel Orman (Causal Forest) analizini entegre ederek ve odak noktasını "neler birbiriyle ilişkili?" sorusundan "nereye müdahale edilebilir?" sorusuna kaydırarak teorik ve metodolojik bir katkı sunmaktadır.

Bu çalışma, makine öğrenimi çerçevesi içinde Türkiye İstatistik Kurumu (TÜİK) ve Dünya Bankası verilerini kullanarak 1990–2024 dönemi için Türkiye'nin emisyon dinamiklerini analiz etmektedir. Modelin açıklanabilirliğini artırmak amacıyla kişi başına GSYİH, fosil yakıt payı, yenilenebilir enerji payı ve ticaret açığı temel değişkenler olarak belirlenmiş; veri sızıntısını önlemek için yüksek korelasyonlu yapısal değişkenler hariç tutulmuştur. Sürekli emisyon verileri, medyan eşik değeri (395,9 Mt) kullanılarak iki dengeli sınıfa dönüştürülmüş ve böylece sorun bir sınıflandırma çerçevesi içinde ele alınmıştır. Analizde Gradient Boosting, Random Forest ve Lojistik Regresyon algoritmaları karşılaştırmalı olarak uygulanmış; hiperparametre optimizasyonu ise 5 katlı çapraz doğrulama kullanılarak gerçekleştirilmiştir. Sınırlı örneklem büyüklüğü ($n=35$) nedeniyle, tahmin önyargısını en aza indirmek için Leave-One-Out Çapraz Doğrulama (LOO-CV) yöntemi tercih edilmiştir. Modellerin "kara kutu" niteliğini aşmak için oyun teorisine dayalı SHAP analizi kullanılmıştır ve değişkenler arasındaki nedensel çıkarımlar, Dual Machine Learning (DML) yaklaşımı kullanılarak Causal Forest aracılığıyla gerçekleştirilmiştir.

Bu çalışma, makine öğrenimi ve nedensel çıkarım yöntemlerini kullanarak Türkiye'nin emisyon dinamiklerini analiz ederek literatüre özgün katkılar sunmaktadır. Sınıflandırma analizinde, Random Forest ve Lojistik Regresyon modelleri en yüksek tahmin performansını sergilemiş ve LOO-CV yöntemi ile $F1=0,973$ puanı elde etmiştir. Bu sonuçlar, metodolojik açıdan Rufaioğlu ve ark. (2025) ile Bakır ve ark. (2022) tarafından yapılan çalışmalarla tutarlıdır; söz konusu çalışmalar, Türkiye'nin emisyon yapısının modellenmesinde toplu öğrenme algoritmalarının başarısını vurgulamaktadır. SHAP analizi, emisyon rejimini belirleyen birincil faktörün GSYİH olduğunu, bunu yenilenebilir enerjinin payının izlediğini göstermektedir. Bu bulgu, Türkiye için Çevresel Kuznets Eğrisi hipotezinin geçerliliğini destekleyen Katırcıoğlu (2014) ve Pata (2018) tarafından yapılan çalışmalarla tutarlıdır. Nedensel Orman analizi, yenilenebilir enerjinin emisyonları ortalama 47.501 Mt azalttığını, dış ticarete açıklığın ise önemli bir artırıcı etkiye (ATE: 23.623 Mt) sahip olduğunu göstermiştir. Dış ticaretin nedensel önemi, kirlilik sığnağı hipotezinin Türkiye'de ikincil bir kanal olarak işlediğini göstermekte ve bu da Cole'un (2004) literatürüne benzersiz bir bakış açısı katmaktadır. SHAP ve Nedensel Orman yöntemlerinin entegre kullanımı, hem değişkenlerin ayırt edici gücünü

hem de müdahalelerin net sonuçlarını netleştirerek, 2007 yılından bu yana kalıcı hale gelen Türkiye'nin yüksek emisyon rejimine karşı bilimsel bir yol haritası sunmaktadır.

Bu çalışma, gelişmiş veri analitiği yöntemlerini kullanarak Türkiye'nin emisyon dinamiklerini modelleyerek literatüre benzersiz bir katkı sunmaktadır. Analiz sonuçlarına dayanılarak geliştirilen temel politika önerisi, emisyon azaltıcı etkileri bilimsel olarak kanıtlanmış yenilenebilir enerji kapasitesine öncelik verilmesidir. Bu süreçte, güneş ve rüzgâr enerjisi yatırımlarının önündeki bürokratik engellerin kaldırılması, kömür santrallerinin aşamalı olarak devreden çıkarılması ve karbon fiyatlandırması gibi piyasa temelli mekanizmaların uygulanması kritik öneme sahiptir. Çalışmanın temel sınırlaması, örneklem büyüklüğünün küçük olmasıdır (n=35). Bu nedenle, enerji dönüşümünün emisyon rejimi üzerindeki etkisinin daha kesin bir şekilde analiz edilebilmesi için, gelecekteki araştırmaların belirli sektörleri daha derinlemesine incelemesi ve daha uzun zaman serileri üzerinde derin öğrenme algoritmaları kullanılarak yürütülmesi önerilmektedir.

Anahtar Kelimeler: Nicel Yöntemler, Sera Gazı Emisyonları, Makine Öğrenimi, Sınıflandırma Analizi, Çevresel Kuznets Eğrisi, SHAP Analizi, Nedensel Orman

www.turkishstudies.net/economy**Turkish Studies - Economics, Finance, Politics**

eISSN: 2667-5625



Classification of Greenhouse Gas Emission Levels in Turkey: An Integrated Assessment via LOO-CV and Causal Forest Analysis

Introduction

Climate change stands out as one of the most comprehensive global environmental problems of the twenty-first century. Reducing greenhouse gas emissions, particularly carbon dioxide (CO₂), is at the center of policy debates on this problem (Jin & Sharifi, 2025). The environmental pressure created by fossil fuel consumption is deepening the tension between economic growth and ecological sustainability. This situation necessitates a systematic analysis of emission determinants from both scientific and policy perspectives (Grossman & Krueger, 1991; Halicioğlu, 2009). Signed in 2015, the Paris Agreement obliges the Parties to set concrete emission reduction targets through national contribution declarations (NDCs) and develop measurable policy instruments to achieve these targets (UNFCCC, 2015). Aydın and Arı (2019) highlight the structural challenges faced by major fossil fuel producers in meeting their Paris Agreement commitments and demonstrate that the gap between declared emission reduction targets and actual policy measures is particularly pronounced in economies with high dependence on fossil fuels. This structural tension can also be directly observed in Turkey's emissions trajectory. In this process, accurately modeling emission dynamics is critical for the effectiveness of policy recommendations.

Turkey is in a unique position in this context. On the one hand, rapid economic growth, urbanization and industrialization put upward pressure on emission levels, while on the other hand, policy objectives to increase renewable energy capacity and reduce energy import dependency become decisive factors shaping the emission trajectory. Turkey's GHG emissions, which were approximately 229 Mt in 1990, reached 584 Mt in 2024 (TurkStat, 2026). Özen et al. (2024) corroborate this trend, finding that human development, urbanization, and industrial and agricultural development are significantly linked to carbon emissions in Turkey -- a multidimensional picture consistent with the rapid socioeconomic transformation underpinning Turkey's rising emission trajectory.

Rufaioğlu et al. (2025) analyzed Turkey's GHG data for the period 2012-2021 and revealed that more than 90% of total emissions are from energy sources. This finding confirms the structural fossil fuel dependence in Turkey's energy mix. Beken et al. (2019) analyzed Turkey's energy efficiency profile in comparison with European countries using the k-Means Clustering algorithm. They show that as the country increases its renewable energy capacity, it approaches more advanced clusters, but the structural transformation is not yet complete.

The use of machine learning methods in modeling emission determinants has become widespread in recent years. In a systematic review of 75 studies published between 2003 and 2023, Jin & Sharifi (2025) showed that hybrid models for estimating urban GHG emissions outperformed single models in terms of both MAPE and MAPE measures. Han & Lin (2025) analyzed long-term emission models with the Environmental Kuznets Curve (EKC) hypothesis using interpretable

machine learning methods, especially through SHAP values, and found that the unique structural characteristics of each country play a critical role in forecasting models. This finding confirms the scientific necessity of approaches that use country-specific data and interpretable algorithms rather than a universal model. This provides a direct theoretical basis for the methodological choice of this study.

However, the majority of Turkey-focused machine learning studies focus on regression-based continuous forecasting problems. Ağbulut (2022) predicted transportation emissions with deep learning and SVM. Ayaz (2024) compared ARIMA and LSTM models with 158 years of historical data. Ene Yalçın (2024) applied linear regression models in a multi-sectoral framework. All of these studies treat the level of emissions as a continuous dependent variable. They leave unanswered the question of whether emissions exceed a policy-relevant threshold, in other words, whether the country has moved to a high or low emission regime. However, the critical question for policymakers is not the exact numerical size of emissions, but whether they exceed the specified threshold.

To address this gap, this study makes four original contributions. The first is to reframe Turkey's GHG emission level as a binary classification problem defined around the median of the GHG series (395.9 Mt CO₂ equivalent). The purpose of choosing the median value is to achieve approximately 1:1 balance between the classes, strengthening both methodological robustness and policy implications based on the findings. Second, we adopt leave-one-out cross-validation (LOO-CV) to overcome the problem of high variance produced by standard k-fold cross-validation under small sample conditions with $n=35$. This will minimize the estimation bias (Arlot & Celisse, 2010). Third, it overcomes the black box nature of ensemble algorithms with the SHAP (SHapley Additive exPlanations) framework, measuring the marginal contribution of each variable to the emissions regime in both magnitude and direction and presenting the findings in a transferable form to policymakers (Lundberg & Lee, 2017). Fourth, CausalForestDML analysis is applied to go beyond the correlation and pattern detection-based structure of SHAP analysis. Thus, the causal effect of each variable on emissions was estimated within the Average Treatment Effect (ATE) framework. In this way, the findings answer the question “what can be intervened?” rather than “what is correlated?”. Moreover, policymakers are provided with causally valid tools (Athey & Imbens, 2016; Chernozhukov et al., 2018). In line with these contributions, the study aims to answer the following research questions: Gradient Boosting, Random Forest and Logistic Regression algorithms are applied comparatively using Turkey's annual data for the period 1990-2024. Only four independent variables with strong theoretical justification are included in the model by systematically eliminating variables at risk of indirect data leakage due to high correlation: GDP, share of fossil fuel consumption, share of renewable energy consumption and trade openness. The rest of the paper is organized as follows: Section 2 reviews the related literature, Section 3 presents the dataset and methodology, Section 4 discusses the findings, and Section 5 presents the conclusions, policy implications and limitations of the study.

1. Can machine learning algorithms meaningfully classify Turkey's GHG emission regime (low and high emissions)?
2. Which macroeconomic and energy variables most strongly determine the emission regime?
3. Can the impact of key variables such as renewable energy share and GDP on emissions be verified by causal inference methods?

Literature Review

The empirical literature on the determinants of greenhouse gas emissions is largely based on the Environmental Kuznets Curve (EKC) hypothesis. This hypothesis, put forward by Grossman and Krueger (1991) in the context of the environmental effects of trade, predicts the existence of an inverted-U-shaped relationship between per capita income and environmental pollution. It argues

that economic growth accelerates environmental degradation until a certain threshold income level is reached, and reduces emissions through technological transformation and structural change after this threshold is exceeded. Among the first comprehensive studies to test this hypothesis for Turkey, Halicioğlu (2009) stands out. Halicioğlu applied error correction model and Granger causality tests to annual data for the period 1960-2005 and found that energy consumption is the primary determinant of emissions. However, the study assumes a linear cointegration relationship and does not consider structural breaks. Gövdeli (2019) empirically tested the EKC hypothesis for Turkey while explicitly accounting for structural breaks, confirming a long-run relationship between income and environmental degradation and underscoring that the income threshold beyond which emissions begin to decline has not yet been reached in the Turkish case. At the regional level, Ravanoglu (2020) tested the validity of the EKC hypothesis for the Eurasian Economic Union using panel data analysis, providing comparative evidence that the income-emissions nexus exhibits institutional and structural variation across country groupings -- a finding that reinforces the importance of country-specific analytical frameworks such as the one adopted in the present study. Kubar and Kıl (2022) tested the validity of the EKC hypothesis for the Fragile Eight -- a country group that includes Turkey -- and G7 economies, demonstrating that the income-environment relationship differs substantially across these two clusters and that structural characteristics of each economy play a decisive role in determining the emissions trajectory. Katırcıoğlu (2014) analyzed the long-run emission effects of tourism revenues and energy consumption using ARDL bounds testing approach. This study also failed to overcome the limitations of the linear model setup. Pata (2018) statistically confirmed the emission-reducing effect of renewable energy consumption with FMOLS and DOLS estimators. However, linear modeling is far from reflecting structural heterogeneity. Han and Lin (2025) revisit this theoretical framework with interpretable machine learning methods and show that the unique circumstances of each country should be taken into account. This finding directly supports the theoretical underpinning of country-specific classification frameworks.

Studies focusing on the impact of energy mix variables on emissions constitute the second important axis of the literature. Apergis and Payne (2009) find a negative long-run relationship between renewable energy consumption and emissions for 16 emerging economies using panel data and show that this relationship is weak in the short run. Shafiei and Salim (2014), in their panel analysis for OECD countries, find that fossil fuel consumption increases emissions while renewable energy produces a significant decreasing effect. The effect of trade openness on emissions is discussed within the framework of the pollution refuge hypothesis. In a related vein, Yılmaz (2020) analyzed the nexus between CO₂ emissions and foreign direct investment, the human development index, and technology, finding that technological improvement and human development contribute to emission reduction while the role of FDI remains context-dependent -- a finding that provides theoretical grounding for the multivariable framework of the present study. In the Turkish context specifically, Özen et al. (2024) examined the relationships among human development, urbanization, industrial development, agricultural development, and carbon emissions, confirming that the multi-dimensional structural drivers of emissions cannot be reduced to a single variable -- a finding directly consistent with the multivariable design of the present study. Focusing on the same N-11 country group as the present study, Açıkgöz and Öncel (2024) conducted a country-based investigation of the effects of economic growth, fossil fuel consumption, and globalization on environmental degradation and found significant cross-country heterogeneity in these effects -- a result that motivates the country-specific classification design adopted here. Cole (2004) has shown that the relatively low environmental standards in developing countries pave the way for dirty industries to move to these countries and create an emission transfer effect. Çoşgun (2024) and Çınarar et al. (2024) emphasized that economic variables such as GDP and population are highly correlated with emissions in the range of 0.92-0.98 in Turkey. This finding provides direct theoretical support for the inclusion of GDP as an independent variable in the current study.

Although the application of machine learning methods to emission forecasting is relatively recent, it has become a rapidly expanding field in recent years. Breiman (2001) introduced the random forest algorithm and Friedman (2001) introduced the gradient boosting method and demonstrated the superior performance of these algorithms in nonlinear relationships both theoretically and empirically. When Turkey-focused machine learning studies are examined, Ağbulut (2022) modeled transportation-related energy demand and emissions with deep learning, SVM and artificial neural networks. This study is the first comprehensive research using these algorithms for Turkey's transportation sector. Ayaz (2024) compared ARIMA ($R^2 = 94.3\%$) and LSTM ($R^2 = 90.4\%$) models with a large data set covering the years 1865-2023. The study showed that traditional time series models perform competitively in long-run dependencies. Rufaioğlu et al. (2025) found that Gradient Boosting ($R^2 = 0.995$) and XGBoost ($R^2 = 0.994$) algorithms achieved the highest accuracy with greenhouse gas data for the period 2012-2021. Ene Yalçın (2024) applied the linear regression model in a multi-sectoral framework covering energy, industrial processes, agriculture and waste sectors. Beken et al. (2019) compared Turkey's energy efficiency with European countries using k-Means Clustering algorithm. In the international literature, Bakır et al. (2022) India; Javanmard & Ghaderi (2022) Iran; Bhatt et al. (2023) USA; and Hasan et al. (2025) Bangladesh have shown that hybrid optimization and ensemble models produce more stable results in small data sets.

In the dimension of model evaluation and interpretability, Leerbeck et al. (2020) modeled the emission intensity in power grids with machine learning and emphasized that this field has significant potential with the increase in data quality and quantity. Jin and Sharifi (2025) showed that the increasing adoption of interpretability tools, especially SHAP values, in emission modeling is critical for policy recommendation. The SHAP framework developed by Lundberg and Lee (2017) adapts the Shapley values derived from cooperation theory to machine learning models to measure the individual contribution of each variable at a consistent, local and global level. Strobl et al. (2007) and Lundberg et al. (2020) have shown that the Gini impurity reduction-based variable importance measure tends to overestimate variables that are correlated with other variables. This finding justifies the methodological choice to present the variable importance analysis together with SHAP values in the present study.

The application of causal inference methods to emissions research is a relatively new field. Pearl (2009) introduced the causal modeling framework as a theoretical basis for the transition from statistical dependence to causal relationships. He showed how to estimate the intervention effect from observational data through structural causal models. Athey and Imbens (2016) proved that heterogeneous “treatment” effects can be estimated unbiasedly with the Causal Forest method they developed by adapting the random forest algorithm to the causal context. Wager and Athey (2018) take this method further and theoretically prove its consistency and asymptotic normality properties. The application of this method to emission research provides an opportunity to directly address the question “in which variable does a policy intervention reduce emissions?”, which SHAP analysis cannot answer. The lack of such causal inference approaches in Turkey-focused machine learning studies makes the current study's integration of this method unique in the literature.

The literature reviewed above points to four main methodological gaps. First, almost all of the Turkey-focused machine learning studies focus on regression-based continuous prediction problems. The issue has not been addressed as a classification problem. Second, model interpretability is not systematically reported in existing studies. This makes it difficult to transfer the findings to policy processes. Third, validation methods specific to small sample conditions, especially LOO-CV studies, are not found in the Turkish literature. Fourth, none of the existing studies systematically combine SHAP analysis with causal inference. The question of whether a variable with high correlation and predictive power will actually respond to a policy intervention

remains unanswered. This paper aims to address this fourth gap by integrating Causal Forest analysis¹.

Methodology

In this study, a modern and objective method is followed in order to overcome the limitations of traditional econometric methods. To this end, machine learning algorithms and explainable artificial intelligence (XAI) techniques are systematically applied together. The modeling process is not restricted to a single theoretical framework or a limited set of variables. A more unbiased and data-driven approach is adopted by building the theoretical rationale on a multidimensional structure of strong variables. Ensemble learning algorithms are used to overcome the limitations of traditional regression-based methods such as model assumption violations, endogeneity and inability to capture nonlinear interactions. The hybrid structure adopted in the study both improves forecasting accuracy and makes the model results explainable in a way that is transferable to policymakers. This methodological combination, collective learning, explainable artificial intelligence, and causal forest, was also used in a study by Sert (2026). The author applied this integrated framework to examine the determinants of global income inequality and demonstrated that combining ensemble algorithms, SHAP-based explainability, and causal forest provides much richer policy insights than any single method applied on its own. This last feature is achieved by interpreting black-box ensemble algorithms such as Gradient Boosting and Random Forest with the SHAP (SHapley Additive exPlanations) and Causal Forest framework (Lundberg & Lee, 2017; Athey & Imbens, 2016). In this section, the dataset is comprehensively introduced and the methodological steps are explained in detail. The methodology followed in the study is presented in Figure 1.²

¹ For studies addressing the environmental, economic, social, and cultural dimensions of climate change, either directly or through related themes—including lake levels, meteorological and hydrometeorological disasters, bioclimatic comfort, air quality, agricultural productivity, and land cover changes; carbon emissions, fossil fuel consumption, climate negotiations, carbon credits, and national climate protection performance; renewable energy education, energy efficiency in buildings and places of worship, ecological architecture, resilient urban mobility, and zero waste management; civil society's contribution to environmental awareness, globalisation, ecological art, sustainable ceramic and textile practices, human–nature relations in literature, representations of environmental sustainability in popular media, and sustainable development in the context of religious values—see also: Bahadır, 2012; Erdoğan & Ganiev, 2016; İçel, 2014; Karataş, 2014; Pınarcıoğlu, 2018; Ulusoy & Atay, 2018; Altıntaş, 2021; Aytepe Serinsu, 2022; Menteşe & Koca, 2025; Akdağ & Parlak Biçer, 2025; Kayaalp & Gürbüz, 2025; Sağır & Çakır, 2026; Doğru & Demirbaş, 2020; İrdem, 2022; Kazel, 2022; Korkmazıyürek et al., 2022; Aytekin & Ateş, 2019; Demir & Süslü, 2022; Süar Oral, 2021; Gökçe & Gökçe, 2020; Aldoori & Benchalel, 2026.

² In conjunction with this body of literature, artificial intelligence applications have become both a subject of study in the social sciences and a significant element of research methodology. For an example, see: Denizci et al. 2018, Baran 2022, Keleş & Keleş, 2018; Karadağ, 2025; Coşkun, 2025; Ahmed & Hamod, 2026; Arıcı & Karacı, 2013; Keleş & Keleş, 2017; Keleş et al., 2017; Bekil, 2018; Keleş, 2018; Serçemeli, 2018; Akyıldız & Akyıldız, 2020; Işık & Darı, 2023; Abdulrazagova et al., 2025; Arğın 2025; Tetik Küçükkelçi, 2025; Çakmak, 2025; Yıldırım Altun, 2025; Zan & Zan, 2025; Mazlum & Mazlum, 2025; Yıldız, 2025; Başar, 2025; Tuğcu, 2025; Özdemir, 2026; Çora et al., 2026; Büyükboyacı & Yozcu, 2026; Ardaturk, 2026; Arduç Kara, 2026; Ertan, 2026; Ahmed & Hamod, 2026; Efendioğlu, 2023; Çelik et al., 2025; Doğru & Hacımüftüoğlu, 2025; Koçakoğlu & Koçakoğlu, 2025; Ekinci, 2025; Sakin & Türk, 2025; Aşkun, 2024; Yener & Köse, 2023; Romya Bilgin & Küçükşabanoğlu, 2023; Çark, 2020; Kanat, 2020; Altındış, 2020; Zenginaloğlu, 2026; Dalmış, 2026; Ölçer, 2025; Sarıbaş, 2025; Karakuş et al., 2025; Güzel, 2024; Kızıldağ, 2023; Odacıoğlu, 2022, Erdem-Demiryakan 2025, Civelek 2025, Günay 2025, Önen 2025, Özdemir 2025; Sandıkcı & Soy 2026; Arduç Kara 2026; Ertan 2026; Uygun 2026; Yılmaz 2025; Kan Çelik 2026; Bayat Arslan & Cuma 2026; Köksal & Zorlu Kale 2025; Varol 2025; Ahmed & Hamod 2026; Efendioğlu 2023; Sert 2026; Güçlüten 2026




Figure 1: Methodology

Source: Developed by the authors.

Dataset

The study utilizes 35 years of data for Turkey for the period 1990-2024. The dependent variable, total greenhouse gas emissions, is compiled from TurkStat Greenhouse Gas Emission Statistics, while the independent variables are compiled from the World Bank Database. The variables used in the analysis are presented in Table 1.

Table 1: Variables, Definitions, and Sources

Variables	Definition	Source
Greenhouse Gases	Total greenhouse gas emissions (Mt CO ₂ eq.)	TUIK
GDP	Gross domestic product per capita (current USD)	World Bank
Fossil Fuels	Share of fossil fuels in total energy consumption (%)	World Bank
Renewable Energy	Share of renewable energy in total final energy consumption (%)	World Bank
Trade Balance	Ratio of trade volume to GDP (%)	World Bank

GDP is included in the model as the main explanatory variable of the ESD hypothesis (Grossman & Krueger, 1991). Fossil fuel share and renewable energy share represent the structural effect of energy mix on emissions (Shafiei & Salim, 2014). Trade openness is added to the model within the framework of the pollution refuge hypothesis (Cole, 2004).

In the initial stage of the study, industrial production index, number of motor vehicles and urbanization rate were also included in the variable pool. However, the Pearson correlation coefficients of these variables with GHG emissions were found to be 0.981, 0.985 and 0.981, respectively, and the correlation between the industrial production index and the number of vehicles reached 0.993. This situation creates a multicollinearity problem (Gujarati & Porter, 2009; Hair et al., 2010) and manipulates the ML algorithm. In other words, it reveals that these variables do not contain independent information explaining greenhouse gas emissions, but rather they are proxy

variables that directly represent emissions. The use of proxy variables with almost deterministic relationships with the target variable in machine learning models leads the model to memorize this relationship instead of learning the true determinants. This situation is called surrogate leakage in the literature (Kaufman et al., 2012). Therefore, these three variables are excluded from the analysis. Only four relatively independent explanatory variables with strong theoretical justification are used in the model.

Descriptive Statistics and Correlation Analysis

During the analysis period, Turkey's annual GHG emissions were between 228.9 Mt (1990) and 584.5 Mt (2024). In this thirty-five-year period, an increase of approximately 2.55 times was observed (Figure 2).




Figure 2. Greenhouse Gas Emission Values (1990–2024)

Figure 2 shows the low and high emission periods according to the threshold value indicating the transition to the high emission regime. Descriptive statistics of the variables used in the analysis are presented in Table 2.

Table 2: Descriptive Statistics (1990–2024)

Variables	Mean	Std. Deviation	Min	Max
Greenhouse Gases	389.7	116.4	228.9	584.5
GDP	7708	3876	2176	15893
Fossil Fuels	86.88	2.54	82.2	91.4
Renewable Energy	16.28	4.44	11.4	24.4
Trade Balance	49.0	11.09	30.5	79.9

The standard deviation of the emission series (116.4 Mt) corresponds to about 30% of the average. This value indicates a high variability of the emission trajectory over the period. The high average fossil fuel share (86.88%) with a relatively low standard deviation (2.54 points) reflects the structural rigidity of Turkey's energy mix. The standard deviation of the share of renewable energy (4.44 points), on the other hand, indicates that this variable underwent a significant transformation over the period and thus has explanatory potential for the model.

The correlation structure between the variables used in the analysis is presented in Figure 3. It is observed that the correlation coefficients between the four variables are significantly below the $|r| = 0.90$ threshold (Gujarati & Porter, 2009; Hair et al., 2010), which is considered as the critical threshold for multicollinearity. The highest correlation is observed between GDP and renewable

energy share, which is negative ($r = -0.90$). This relationship reflects a structural pattern in which energy demand increases during economic growth and the share of renewable energy relatively declines. The negative correlation between fossil fuel share and renewable energy share ($r = -0.88$) confirms the expected theoretical direction of the substitution relationship in the energy mix.




Figure 3. Pearson Correlation Coefficients for the Variables

Missing Values

Two main gaps were identified in the raw dataset. Fossil fuel consumption data is not reported in the World Bank database for six observations covering the period 2016-2021. It is assessed that this deficiency is due to the delay in the data reporting process. Renewable energy share data is not yet finalized for 2022-2024. Both gaps have been eliminated by linear interpolation. Backfill and forward fill methods were applied for the missing data at the endpoints of the dataset. After the completion process, there were no missing observations in the data set.

Creating the Target Variable

In order to apply machine learning-based classification analysis, the continuous greenhouse gas emission variable needs to be transformed into a categorical target variable. For this reason, the dependent variable, greenhouse gas emissions (Mt), was transformed into two classes based on the median value (395.9 Mt). Observations below the median are coded as low emissions (class 0), while observations above the median are coded as high emissions (class 1). The main rationale for this operationalization decision is statistical. While a mean-based threshold is sensitive to outlier observations in right-skewed variables such as GHG emissions, a median-based threshold provides a split point that is distribution-independent and robust to outliers (Terzioglu et al., 2026). This choice produces a balanced class distribution of 17 low emission and 18 high emission observations with a ratio of approximately 1:1, well below the 4:1 ratio defined by He and Garcia (2009) as the threshold for severe imbalance. This balance structurally eliminates the risk of bias due to class imbalance in small samples ($n = 35$) and reinforces the reliability of the cross-validation process through F1 score optimization. The median threshold represents relative in-sample performance, not a normative emission target, and provides a sector-independent, interpretable benchmark (Terzioglu et al., 2026).

Machine Learning Algorithms

In this study, three classification algorithms were applied comparatively. The choice of algorithm was driven by two main criteria: stable performance under small sample conditions and favorable model interpretability.

Gradient Boosting (GB) is an ensemble learning method developed by Friedman (2001). The algorithm is based on assembling sequentially trained weak learners (decision trees). Each new tree minimizes the residual error of the previous one. At step t , the model is updated with Formula 1:

$$F_t(x) = F_{t-1}(x) + \eta \cdot h_t(x) \quad (1)$$

Where $F_{t-1}(x)$ is the prediction function of the previous step, $h_t(x)$ is the contribution of the new weak learner and η is the learning rate. This update in the direction of the gradient of the loss function provides the capacity to model nonlinear relationships between variables and high-order interactions.

Random Forest (RF) is a bootstrap aggregating ensemble proposed by Breiman (2001). Each decision tree is trained on subsets that are iteratively sampled (bootstrap) from the original data set. Each tree uses a randomly selected feature subset. The classification decision is obtained by majority voting (Formula 2):

$$\hat{y} = \arg \max_k \sum_{b=1}^B 1 [h_b(x) = k] \quad (2)$$

Training each tree on a random subset of features breaks the correlation between individual trees, reducing the variance of the ensemble and increasing its generalization power. Thanks to its tree-based structure, the Random Forest algorithm is able to model non-linear relationships and high-order interactions between variables. The bagging strategy based on bootstrap sampling and randomly selected feature subsets in each bin breaks the correlation between individual trees, reducing the variance of the ensemble and providing the model with a structural resistance to overfitting (Breiman, 2001).

Logistic Regression (LR) is a parametric classifier based on the assumption of a linear decision boundary. For binary classification, the class probability is modeled by means of the logistic (sigmoid) function as follows (Formula 3):

$$P(y = 1 | x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)}} \quad (3)$$

In this study, LR is included in the model both as a linear baseline and to quantify the additional value offered by non-linear methods.

Preprocessing and Data Leakage Control

All numerical features were subjected to Z-score standardization (Formula 4):

$$z = \frac{x - \mu}{\sigma} \quad (4)$$

The standardization parameters (μ and σ) are computed only on the training data; they are applied externally to the test data. This practice structurally prevents information leakage from the test set to the training set. All preprocessing and modeling steps were chained within the scikit-learn pipeline structure and re-implemented independently for each validation layer.

Hyperparameter Optimization

The hyperparameters of each algorithm are optimized by the grid search (GridSearchCV) method. Stratified 5-fold cross-validation was used as an internal validation mechanism during the optimization process. This ensures proportional representation of both classes in each layer. The F1 score, which is sensitive to class imbalance, is adopted as the score criterion. Learning rate (η), tree depth and number of trees for Gradient Boosting; number of trees, maximum depth and minimum branch splitting threshold for Random Forest; regularization parameter C and solver selection for Logistic Regression were optimized.

Model Evaluation: Leave-One-Out Cross-Validation

In this study, Leave-One-Out Cross-Validation (LOO-CV) is used as the primary model evaluation method. For a dataset of n observations, LOO-CV retains only one observation as a test set at each iteration and retrains the model on the remaining $n - 1$ observations.

This process is repeated for all n observations. The LOO-CV prediction error is calculated by Formula 5:

$$\text{LOO-CV Error} = \frac{1}{n} \sum_{i=1}^n L(y_i, \hat{f}^{(-i)}(x_i)) \quad (5)$$

Where $\hat{f}^{(-i)}$ is the model trained by excluding the i -th observation and L is the loss function. In this study, $n = 35$ and each test set contains only 7 observations in the standard 5-fold CV. This increases the evaluation variance and makes the performance estimates unstable. LOO-CV, on the other hand, minimizes prediction bias by working with a training set of $n - 1 = 34$ observations in each iteration. Arlot and Celisse (2010) theoretically demonstrated that LOO-CV produces predictions with lower bias compared to standard k -fold methods at small sample sizes.

Model performance was evaluated using accuracy, precision, recall and F1 score. Considering the class imbalance, the harmonic mean F1 score was adopted as the primary measure (Formula 6):

$$F1 = 2 \cdot \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (6)$$

Model Interpretability: SHAP Analysis

Although machine learning models have high predictive power, they are generally black boxes. This makes it difficult to understand which variables contribute to the model in which direction and to what extent. In order to overcome this constraint, Explainable Artificial Intelligence (XAI) techniques are used in the economics and policy literature (Gunning & Aha, 2019). In this study, SHAP (SHapley Additive exPlanations) method, one of the XAI techniques, was used.

Based on Shapley values, one of the basic concepts of game theory, SHAP calculates the marginal contribution of each variable to the prediction output of the model over all possible combinations of variables (Lundberg & Lee, 2017). The SHAP value of the i -th attribute for the j -th observation is defined by Formula 7:

$$\phi_j(i) = \sum_{S \subseteq F \setminus \{j\}} \frac{|S|! (|F| - |S| - 1)!}{|F|!} [f_{S \cup \{j\}}(x_i) - f_S(x_i)] \quad (7)$$

Where F denotes the set of all features, S denotes any subset other than the feature, and $f_S(x_i)$ denotes the model estimated with only the features in the set S . The total predicted value of the model is obtained by summing the marginal contributions of all variables. SHAP values satisfy the efficiency ($\sum_j \phi_j = f(x) - E[f(x)]$), symmetry and dummy variable axioms. In this way, it measures the contribution of variables at a consistent, local and global level.

However, SHAP, like other XAI techniques, only measures the contribution of variables to the forecast. It cannot guarantee whether this contribution corresponds to a causal relationship (Adadi & Berrada, 2018; Molnar, 2022). As possible ordering differences between variable importance analysis and SHAP may be due to the tendency of the Gini impurity reduction measure to overestimate correlated variables (Strobl et al., 2007; Lundberg et al., 2020), this study takes SHAP findings as the primary interpretation reference.

Causal Forest Analysis

Given that SHAP analysis does not guarantee causality, causal inference methods have been used to estimate the actual causal effects of variables on GHG emissions (Neuberg, 2003). The main purpose of causal inference is to isolate the effect of a change in one variable by one unit on the dependent variable. For this purpose, we used the Causal Forest method developed by Athey and Imbens (2016), which adapts the classical random forest algorithm to the causal context.

The main feature of the Causal Forest is that the branching criteria of the tree structure are not based on minimizing the prediction error, but on maximizing the differences in the conditional mean “treatment” effect of the variable. In addition, its data separation strategy (honesty) structurally reduces the risk of overlearning by using one subset for determining tree splitting rules and the other subset for estimating effects (Wager & Athey, 2018). In this way, complex and non-linear causal relationships can be modeled without the need for linear assumptions.

In this study, causal forest analysis is implemented with the CausalForestDML algorithm of the Microsoft EconML library. Based on the Double Machine Learning (DML) framework, this approach utilizes Gradient Boosting estimators for both the output and treatment models, systematically removing the effect of observable confounders (Chernozhukov et al., 2018). As a result of the SHAP analysis, the variables that were determined to have a high contribution value were defined as “treatment” variables in turn. Each time, the marginal causal effect of the relevant variable was estimated by keeping the remaining variables conditional. The method is interpreted under the assumptions of conditional independence and sufficient overlap, where observable confounders are included in the model. In this study, the average treatment effect (ATE) is calculated.

Findings

This section presents the findings of machine learning-based classification analysis applied to Turkey's greenhouse gas emissions data for the period 1990-2024. The results of hyperparameter optimization, LOO-CV model performance, confusion matrix, variable importance analysis, SHAP analysis and Causal Forest analysis are discussed respectively. The findings reveal both the predictive success of the models and the direction and magnitude of emission determinants.

The optimal hyperparameters of all three algorithms are determined by grid search and stratified 5-fold cross-validation. The optimization results are shown in Table 3.

Table 3. Hyperparameter Optimization Results

Model	Optimum Parameters	CV5 F1	CV5 Std
Gradient Boosting	lr=0.05, depth=2, n=100	1.000	0.000
Random Forest	depth=None, split=2, n=100	0.971	0.057
Logistic Regression	C=1, solver=lbfgs	0.971	0.057

When Table 3 is analyzed, it is seen that Random Forest and Logistic Regression exhibit the same CV5 F1 profiles, while Gradient Boosting algorithm exhibits higher CV5 F1 profiles. Gradient Boosting achieved CV5 F1 = 1.000 with the optimal parameters of learning rate 0.05, maximum tree depth 2 and number of trees 100. The standard deviation is zero, indicating that perfect classification is achieved at each level of the five-fold cross-validation. This result is due to the ~1:1 class balance provided by the median threshold and the low-depth tree structure (depth=2) working together on the small dataset. However, it should be noted that the CV5 evaluation was performed on test sets of 7 observations and therefore may produce an optimistic performance estimate. Indeed, in the LOO-CV evaluation, GB F1 = 0.971, which clearly demonstrates the over-optimism of CV5. Random Forest and Logistic Regression equal CV5 F1 score (0.9714). The standard deviation of both models remains at 0.0571, indicating a consistent but imperfect learning behavior across different training subsets. This pattern is methodologically indicative of a more reliable generalization capacity. When the optimal parameters are examined, it is seen that unlimited tree depth (depth=None) and branch splitting with a minimum of 2 observations were chosen for Random Forest, and C=1 regularization coefficient was chosen for Logistic Regression. These parameters are the result of GridSearchCV's systematic grid search with stratified 5-fold cross-validation and F1 score criterion, ensuring proportional representation of both classes in each stratum.

LOO-CV Model Performance

LOO-CV evaluation results are presented in Table 4 and Figure 4.

Table 4. LOO-CV Model Performance Metrics

Model	Accuracy	Precision	Recall	F1
Gradient Boosting	0.971	1.000	0.944	0.971
Logistic Regression	0.971	0.947	1.000	0.973
Random Forest	0.971	0.947	1.000	0.973

According to Table 4, Random Forest and Logistic Regression achieved equal F1 scores (0.973) in the LOO-CV evaluation. Gradient Boosting performed very close with F1 = 0.971. The fact that the three models produce similar LOO-F1s suggests that the four available variables contain enough information to reliably distinguish the transition to a high emission regime. Figure 4 presents a comparative view of the three models in terms of four different performance metrics (accuracy, precision, recall, F1).




Figure 4. Comparison of Model Performance Metrics

It is particularly noteworthy that the precision value of the Gradient Boosting model is 1.000. This finding shows that the model does not produce false positives in observations labeled as high emission class and exhibits a highly reliable discriminative structure in the detection of the high emission regime. In the context of climate policy, this feature has a critical practical value: it implies that policymakers benefit from a tool that accurately detects the high emission regime, rather than

triggering unnecessary alarms. A year-by-year view of the LOO-CV classification results is presented in Figure 5. It can be seen that the misclassified observations correspond to years in the transition period close to the median threshold (range 2006-2008). This reflects a methodologically expected pattern. It reveals that the model misclassifies uncertain observations near the threshold, while correctly labeling observations far from the threshold with confidence.




Figure 5. LOO-CV Classification Results

Confusion Matrix

The LOO-CV confusion matrix of the Gradient Boosting model is presented in Figure 6. 34 out of 35 observations are correctly classified; only 1 observation is misclassified. 16 out of 17 observations of the low emission class are correctly labeled, and all 18 observations of the high emission class are correctly classified. Only 1 observation was mislabeled. This result confirms that the balanced class structure with median threshold improves model stability.




Figure 6. Confusion Matrix

Variable Importance Analysis

Figure 7 shows the variable importance hierarchy of the factors affecting Turkey's GHG emissions for the period 1990-2024 analyzed by three different methods. In all analyses based on Gini Impurity Reduction, Permutation Importance and SHAP values, GDP variable is found to be the most dominant determinant of emissions. Especially in the Permutation analysis, GDP has the highest share with a score of 0.4925, confirming that economic size is the main driving force shaping the volume of emissions in Turkey.




Figure 7. Variable Importance Levels

In terms of the energy mix, the share of Renewable Energy use ranks second in both Gini and SHAP analyses and plays a more critical role in explaining emissions variance than Fossil Fuel use. In the marginal contribution hierarchy presented by SHAP values, Renewable Energy (0.3012) outperforms Fossil Fuel (0.1648) by almost two times, proving that the transition to clean energy is of strategic importance in estimating emissions. On the other hand, the Trade Openness variable has the lowest importance score in all three methods, suggesting that the impact of trade liberalization on emissions in Turkey lags behind endogenous dynamics such as the volume of economic production and energy resource structure. The results demonstrate with methodological consistency that the relationship between economic growth and energy transition is central to emission control strategies.

SHAP Analysis

The SHAP summary plot of the Random Forest model created to estimate GHG emission levels (Class 0: Low, Class 1: High) is presented in Figure 8. This figure explains the decision mechanism of the model by detailing both the direction and magnitude of the effect of independent variables on model outputs on a sample basis.




Figure 8. SHAP Analysis

Figure 8 shows that the strongest discriminating factor determining the emission class is GDP (USD). For Class 1 (High Emission), the clustering of high values of the GDP variable (red dots) in the region of positive SHAP values indicates that an increase in economic size directly and strongly increases the probability of being included in the high emission class. In contrast, low GDP values (blue dots) have a negative effect, pushing emissions into the low class.

In terms of energy sources, the use of Renewable Energy (%) is found to have a suppressive effect on the high emission class. The fact that the increase in the share of renewable energy (red dots) has negative SHAP values for Class 1 output proves that switching to green energy reduces the risk of being in the high emission group. On the contrary, an increase in the use of Fossil Fuel (%) has a tendency to increase emissions, but this effect does not have as large an impact area (SHAP distribution width) as GDP. The trade openness variable, on the other hand, exhibits a narrower distribution around the zero point of the SHAP axis, suggesting a much more limited and uncertain marginal contribution to Turkey's emissions classification compared to other variables. In sum, the analysis confirms that the volume of economic growth is the main driver of high emissions in Turkey and that renewable energy is positioned as the most strategic tool to break this negative impact.

Causal Forest Analysis

SHAP and variable importance analyses reveal the strength and direction of statistical relationships between variables. However, these methods are not designed for causal inference. Measuring the marginal contribution of a variable to model output is different from estimating the causal effect of a policy intervention on emissions. To explicitly address this distinction, Causal Forest analysis is included in the study. The average causal effect values (Average Treatment Effect - ATE) for the analysis were calculated for the whole sample. The ATE results are shown in Figure 9.




Figure 9. Average Treatment Effect (ATE) of Variables on Greenhouse Gases

When the ATE findings (Figure 9) are analyzed, it is seen that an increase in the share of renewable energy reduces GHG emissions by -47.501 Mt on average. This effect is statistically significant as the 95% confidence interval does not include zero. An increase in the GDP variable increases emissions by 46.507 Mt on average. Under certain assumptions, this finding supports the SHAP finding that the turning point of the CCE hypothesis has not yet been exceeded in the case of Turkey, also on the causal level. The incremental effect of trade openness on emissions (ATE:

+23.623 Mt), which appeared to be of low significance in previous analyses, was statistically significant in the causal model, indicating that the pollution refuge mechanism has left a causal imprint in Turkey.

The effect of fossil fuel share on emissions is estimated as -31.607 Mt, but this effect is statistically insignificant as the confidence interval contains zero. This suggests that although fossil fuel use is strongly correlated in determining the emission regime, its effect as a causal intervention variable is highly uncertain (wide confidence interval) at this sample size. This finding suggests that with a limited sample size of $n=35$, the Causal Forest algorithm may struggle to produce reliable forecasts for some variables and that larger data sets are needed for the full effectiveness of the method.

At this point, it should be emphasized that SHAP and Causal Forest findings complement each other but answer different questions. While SHAP analysis answers the question ‘which variable is the strongest discriminant in emission estimation?’, Causal Forest focuses on the question ‘which variable does an intervention change emissions in the most reliable way? In this framework, in terms of statistical significance and effect size, the share of renewable energy (-47.501 Mt) stands out as the most effective policy instrument for emission reduction. The hierarchical differences presented by the two methods are not a contradiction, but rather provide methodological depth for policymakers: While economic growth and the current energy structure are the main determinants of emissions, the causal analysis suggests that under the conditional independence assumption controlling for observable confounders, increasing renewable energy capacity is associated with a more predictable emissions reduction.

Conclusions

This study examines the determinants of Turkey's greenhouse gas emission level with annual data for the period 1990-2024 using machine learning-based classification method. Gradient Boosting, Random Forest and Logistic Regression algorithms are comparatively evaluated in the binary classification framework based on the 395.9 Mt CO₂ equivalent threshold, which is the median of the greenhouse gas series; the performance of the models is measured by LOO-CV and interpretability is deepened by SHAP analysis and Causal Forest method.

According to the LOO-CV results, Random Forest and Logistic Regression performed $F1 = 0.973$ and Gradient Boosting performed $F1 = 0.971$. The fact that the precision value of Gradient Boosting and Logistic Regression models reaches 1.000 reveals that zero false positives are generated in the detection of high emission regime and the model exhibits a reliable discriminative structure for policy applications. The SHAP analysis identified GDP as the primary variable determining the emission regime. Other determinants are renewable energy share, fossil fuel share and trade openness, respectively. The Causal Forest analysis complemented the SHAP findings from a causal perspective by emphasizing the share of renewable energy (ATE: -47.501 Mt) and GDP (ATE: 46.507 Mt) in terms of statistical significance. The findings also reveal that Turkey has permanently shifted to a high emission regime since 2007.

The study makes four main contributions to the literature. First, its reconstruction of the GHG emission variable as a classification problem instead of a regression problem makes it possible to directly transfer the findings to climate policy processes. Second, reliable model evaluation is provided with LOO-CV under small sample conditions. Thus, data leakage and overlearning risks are structurally eliminated. Third, the integration of the SHAP framework transforms ensemble algorithms into an interpretable analysis tool. Fourth, with the addition of Causal Forest analysis, the methodological distinction between correlation and causality is made explicit, providing policy makers with an answer to the question “what can be intervened?”, not just “what is correlated?”.

Regarding the first question, LOO-CV results show that machine learning algorithms can classify Turkey's GHG emission regime with high accuracy. Regarding the second question, SHAP analysis identified GDP as the primary determinant, followed by renewable energy share, fossil fuel share and trade openness. Regarding the third question, Causal Forest analysis finds the causal effect of renewable energy share and GDP on emissions to be statistically significant, while the effect of fossil fuel share fails to reach significance due to small sample size.

Discussion

The findings of this study are largely in line with the existing literature on the determinants of GHG emissions in Turkey, but differ in a few important points and offer original contributions to the literature.

When the performance of the classification models is evaluated, it is seen that Random Forest and Logistic Regression algorithms exhibit a strong and stable predictive power with LOO-CV $F1 = 0.973$. Gradient Boosting also performed very close with $F1 = 0.971$. Rufaioğlu et al. (2025) showed that Gradient Boosting achieved the highest accuracy with $R^2 = 0.995$ in Turkey's greenhouse gas data. At the methodological level, the integrated use of ensemble algorithms, SHAP analysis, and causal forest inference in the present study parallels the approach validated by Sert (2026), where the same methodological triplet was shown to produce causally grounded, policy-transferable insights in a socioeconomic context distinct from emissions modeling. These parallel findings in different problem frameworks such as regression and classification consistently confirm the superiority of ensemble learning algorithms in modeling Turkey's emission dynamics.

The fact that GDP emerges as the primary determinant in the SHAP analysis supports the conditional validity of the EKC hypothesis for Turkey and is consistent with the long-term findings of Katırcıoğlu (2014), Pata (2018), and Gövdeli (2019). These researchers have confirmed that, in the context of structural breaks, Turkey has not yet passed its income inflexion point. This finding is also confirmed by Açıkgöz and Öncel (2024) at the N-11 level. These researchers have demonstrated that the impact of economic growth on environmental degradation is significantly heterogeneous across N-11 economies. This finding is consistent with Turkey's classification as a high-emission regime. The fact that the share of renewable energy exhibits a significant second-order emission-reducing effect supports the findings of Pata (2018) and Beken et al. (2019), who show that Turkey moves closer to the cluster of countries with a lower emission profile as renewable energy capacity increases.

The bidirectional SHAP distribution of GDP provides a valuable finding in terms of the ESD hypothesis. The fact that lower GDP values increase the likelihood of higher emissions is in line with the literature (Katırcıoğlu, 2014; Pata, 2018) that discusses whether Turkey has reached the turning point yet.

Han & Lin (2025) show that country-specific threshold conditions emerge when the CCE hypothesis is treated with interpretable machine learning. This finding supports the nonlinear SHAP distribution of GDP at the theoretical level.

The fact that trade openness ranks last in the SHAP analysis partially contradicts Cole's (2004) findings, which strongly support the pollution haven hypothesis. However, the Causal Forest analysis reveals that the ATE value for this variable is 23,623 Mt and that the confidence interval does not include zero. This finding indicates that, although trade openness has limited predictive power, it has a significant positive effect on emissions at the causal level. This suggests that, in the case of Turkey, the pollution haven mechanism operates as a secondary and conditional channel rather than a primary one. This finding is generally consistent with Yılmaz (2020), who shows that the relationship between trade-related variables and CO₂ emissions is mediated by institutional and

technological factors. This suggests that the pollution haven mechanism operates not as a uniform channel, but rather as a conditional channel shaped by country-specific structural characteristics.

The Causal Forest analysis produced results that complement the SHAP findings but from a different perspective. The ATE of the fossil fuel share, which ranks third in the SHAP, is not statistically significant (ATE: -31.607 Mt, Confidence Interval: [-67, +13]). On the other hand, the share of renewable energy (ATE: -47.501 Mt, Confidence Interval: [-63, -32]) and GDP (ATE: +46.507 Mt, Confidence Interval: [+30, +63]) reached statistical significance on the causal plane. This result is also confirmed by Ayvaz Güven (2026). Using panel estimates for G20 countries, the author demonstrated that renewable energy consumption significantly reduces the carbon ecological footprint. The fact that the causal forest estimation for Turkey is consistent with the panel-based estimation for the G20 strengthens the external validity of this finding. Trade openness also has a positive and significant causal effect on emissions (ATE: +23.623 Mt). This decomposition makes it clear that SHAP and Causal Forest methods answer different questions: SHAP answers the question “which variable decomposes the emission class most strongly?”, while Causal Forest answers the question “which variable intervention reduces emissions most reliably?”. The combination of the two methods produces much richer and more policy-relevant findings than either method alone. The failure of the fossil fuel share to reach statistical significance is largely due to the inability of the Causal Forest algorithm to adequately handle the narrow variation in the “treatment” variable (fossil fuel share ranges between 82-91%) in a small sample size of $n = 35$.

At the methodological level, the performance achieved with LOO-CV $F1 = 0.973$ is comparable to the findings of Bakır et al. (2022) and Hasan et al. (2025), which show that ensemble models produce more stable results in small data sets. A precision of 1,000 is particularly valuable for policy applications. This provides a tool that accurately detects the high emission regime without generating unnecessary alarms. Leerbeck et al.'s (2020) emphasis on the significant potential of the field with improved data quality remains a concrete guideline for future research in the context of the limitations of this study with $n = 35$ observations.

Policy Recommendations

The findings of the study lead to concrete interlinked recommendations for Turkey's climate policy design.

Prioritization of renewable energy capacity. Causal Forest analysis revealed that an increase in the share of renewable energy statistically significantly reduces GHG emissions (ATE: -47.501 Mt). This finding suggests that expanding renewable energy capacity can be a primary policy lever not only for energy supply security but also for direct climate policy objectives. Reducing bureaucratic and financial barriers to solar and wind energy investments, developing energy storage capacity and promoting distributed generation models can be presented as instruments that can be considered in this direction.

Reducing fossil fuel dependency. SHAP analysis identified fossil fuel share as the third variable determining the emission regime. However, the fact that it comes after GDP and renewable energy share does not diminish the importance of this variable in terms of policy. Although the ATE value of this variable did not reach statistical significance in the Causal Forest analysis, this result does not reflect ineffectiveness but rather measurement difficulties due to sample size constraints. Phasing out coal power plants, reducing natural gas dependence and removing obstacles to energy efficiency investments can be considered as components of structural transformation that should be prioritized.

Managing the growth-emissions relationship. Both the non-linear distribution of GDP in the SHAP analysis and its significant increasing effect in the Causal Forest (ATE: 46,507 Mt) indicate that the economic growth strategy should be designed in integration with climate policy. Considering

that environmental policy budgets come under pressure and energy-intensive sectors gain relative weight, especially in times of economic contraction, it is crucial that market-based instruments such as carbon pricing and green tax reform are embedded in a stable policy framework that operates independently of the economic cycle.

Limitations of the Study and Suggestions for Future Research

This study has some limitations.

First, the analysis is based on a relatively small sample of $n = 35$ annual observations. While LOO-CV methodologically minimizes this limitation, the reliability of both classification and causal inference estimates would naturally increase with larger samples. This limitation is particularly pronounced in the Causal Forest analysis: the confidence interval for the fossil fuel share contains zero, largely due to the small sample and the narrow variation in the “treatment” variable. More than a hundred observations are required for the algorithm to capture significant effect differences (Wager & Athey, 2018).

The second limitation is the adoption of a single statistical reference point (395.9 Mt-median) as the classification threshold. How the model behavior differs under alternative thresholds was not examined in this study. Robustness testing using different thresholds instead of the median threshold can be suggested for future studies.

Third, the study works with national aggregated data and does not consider the sectoral breakdown of GHG emission dynamics (energy, transportation, industry, agriculture and waste, etc.) separately. Machine learning-based analyses at the sectoral level can significantly improve the effectiveness of both classification models and causal inference methods.

Several directions for future research stand out. Adopting a multi-class classification design could allow for finer disaggregation of emission regimes. The use of quarterly data could quadruple the sample size, increasing the reliability of both classification and Causal Forest analyses. The application of deep learning architectures, such as long short-term memory networks (LSTM) or temporal convolutional networks (TCN), when longer time series data are available would offer a comparative methodological perspective. However, these architectures usually require more than a hundred observations to work effectively (Goodfellow et al., 2016). Finally, comparative panel analyses covering economies at a similar development level as Turkey can reveal how the impact of the energy transition on the emissions regime differs across countries.



www.turkishstudies.net/economy

Turkish Studies - Economics, Finance, Politics

eISSN: 2667-5625



ANKARA SCIENCE
UNIVERSITY

Türkiye'nin Sera Gazı Emisyon Düzeyinin Sınıflandırılması: LOO-CV ve Nedensel Orman Analizi ile Bütünleşik Bir Değerlendirme

Giriş

İklim değişikliği, yirmi birinci yüzyılın en kapsamlı küresel çevre sorunlarından biri olarak öne çıkmaktadır. Bu soruna ilişkin politika tartışmalarının merkezinde karbon dioksit (CO₂) başta olmak üzere sera gazı emisyonlarının azaltılması yer almaktadır (Jin & Sharifi, 2025). Fosil yakıt tüketiminin yarattığı çevresel baskı, ekonomik büyüme ile ekolojik sürdürülebilirlik arasındaki gerilimi giderek derinleştirmektedir. Bu durum emisyon belirleyicilerinin sistematik biçimde analiz edilmesini hem bilimsel hem de politika açısından zorunlu kılmaktadır (Grossman & Krueger, 1991; Halicioğlu, 2009). 2015 yılında imzalanan Paris Anlaşması, taraf ülkeleri ulusal katkı beyanları (NDC) aracılığıyla somut emisyon azaltım hedefleri belirlemeye ve bu hedeflere ulaşmak için ölçülebilir politika araçları geliştirmeye zorlamaktadır (UNFCCC, 2015). Aydın ve Arı (2019), büyük fosil yakıt üreticilerinin Paris Anlaşması taahhütlerini yerine getirirken karşılaştıkları yapısal zorlukları ortaya koymakta ve beyan edilen emisyon azaltma hedefleri ile fiili politika önlemleri arasındaki uçurumun, fosil yakıta bağımlılığı yüksek ekonomilerde özellikle belirgin olduğunu göstermektedir. Bu yapısal gerilim, Türkiye'nin emisyon seyrinde de doğrudan gözlemlenebilmektedir. Bu süreçte emisyon dinamiklerini doğru biçimde modelleyebilmek, politika önerilerinin etkinliği açısından kritik bir öneme sahiptir.

Türkiye, bu bağlamda kendine özgü bir konumda bulunmaktadır. Bir yandan hızlı ekonomik büyüme, kentleşme ve sanayileşme süreci emisyon düzeylerini yukarı yönde baskımlarken, öte yandan yenilenebilir enerji kapasitesini artırma ve enerji ithalat bağımlılığını azaltma yönündeki politika hedefleri emisyon yörüngesini şekillendiren belirleyici unsurlar haline gelmektedir. Türkiye'nin 1990 yılında yaklaşık 229 Mt olan sera gazı emisyonu 2024 yılında 584 Mt düzeyine ulaşmıştır (TÜİK, 2026). Özen ve ark. (2024), bu eğilimi doğrulayarak, Türkiye'de insani gelişme, kentleşme ile sanayi ve tarımsal gelişimin karbon emisyonlarıyla önemli ölçüde bağlantılı olduğunu ortaya koymuştur. Bu çok boyutlu durum, Türkiye'nin artan emisyon eğrisinin temelini oluşturan hızlı sosyoekonomik dönüşümlerle tutarlıdır.

Rufaioglu vd. (2025), Türkiye'nin 2012-2021 dönemine ait sera gazı verilerini inceleyerek toplam emisyonların %90'ından fazlasının CO₂ kaynaklı olduğunu ortaya koymuştur. Bu bulgu Türkiye'nin enerji karimasındaki yapısal fosil yakıt bağımlılığını teyit etmektedir. Beken vd. (2019) ise k-Ortalamlar Kümeleme algoritmasıyla Türkiye'nin Avrupa ülkeleriyle karşılaştırmalı enerji verimliliği profilini analiz etmiştir. Ülkenin yenilenebilir enerji kapasitesini artırdıkça daha gelişmiş kümelerle yaklaştığını, ancak yapısal dönüşümün henüz tamamlanmadığını göstermiştir.

Emisyon belirleyicilerinin modellenmesinde makine öğrenmesi yöntemlerinin kullanımı son yıllarda hızla yaygınlaşmıştır. Jin & Sharifi (2025), 2003–2023 yılları arasında yayımlanan 75 çalışmayı kapsayan sistematik derleme çalışmalarında kentsel sera gazı emisyonlarının tahminine

yönelik hibrit modellerin, tekil modellere kıyasla hem R^2 hem de MAPE ölçütleri açısından daha üstün performans sergilediğini göstermiştir. Han & Lin (2025) ise uzun vadeli CO_2 emisyon modellerini Çevresel Kuznets Eğrisi (ÇKE) hipoteziyle birlikte yorumlanabilir makine öğrenmesi yöntemleriyle, özellikle SHAP değerleri aracılığıyla, analiz ederek her ülkenin kendine özgü yapısal özelliklerinin tahmin modellerinde kritik bir rol oynadığını ortaya koymuştur. Bu bulgu, evrensel bir model yerine ülkeye özgü veriler ve yorumlanabilir algoritmalar kullanan yaklaşımların bilimsel gerekliliğini doğrulamaktadır. Bu durum, çalışmanın metodolojik tercihine doğrudan teorik zemin oluşturmaktadır.

Bununla birlikte Türkiye odaklı makine öğrenmesi çalışmalarının büyük bölümü regresyon tabanlı sürekli tahmin problemlerine odaklanmaktadır. Ağbulut (2022), ulaştırma kaynaklı CO_2 emisyonlarını derin öğrenme ve SVM ile tahmin etmiştir. Ayaz (2024), 158 yıllık tarihi veriyle ARIMA ve LSTM modellerini karşılaştırmıştır. Ene Yalçın (2024) ise çok sektörlü bir çerçevede doğrusal regresyon modellerini uygulamıştır. Bu çalışmaların tamamı emisyon düzeyini sürekli bir bağımlı değişken olarak ele almaktadır. Emisyonun politika açısından anlamlı bir eşiği aşp aşmadığı sorusuna bir başka ifadeyle ülkenin yüksek ya da düşük emisyon rejimine geçip geçmediğini yanıtızsız bırakmaktadır. Oysa politika yapıcılar açısından asıl kritik soru, emisyonun tam sayısal büyüklüğünden çok belirlenen eşik değerini aşp aşmadığıdır.

Bu çalışma söz konusu boşluğu gidermek amacıyla dört özgün katkı sunmaktadır. Birincisi, Türkiye'nin sera gazı emisyon düzeyini sera gazı serisinin medyanı (395,9 Mt CO_2 eşdeğeri) etrafında tanımlanmış ikili sınıflandırma problemi olarak yeniden çerçevelemektir. Medyan değerinin seçilmesinin amacı sınıflar arasında yaklaşık 1:1 denge sağlayarak hem metodolojik sağlamlığı hem de bulgulara dayalı politika çıkarımlarını güçlendirmektedir. İkincisi, $n=35$ olan küçük örneklem koşullarında standart k-katlı çapraz doğrulamanın ürettiği yüksek varyans sorununu aşmak amacıyla bırak-bir-dışarıda çapraz doğrulama (LOO-CV) yöntemini benimsemesidir. Bu sayede tahmin yanlılığı minimize edilecektir (Arlot & Celisse, 2010). Üçüncüsü, topluluk algoritmalarının kara kutu niteliğini SHAP (SHapley Additive exPlanations) çerçevesiyle aşarak her bir değişkenin emisyon rejimine olan marjinal katkısını hem büyüklük hem yön boyutunda ölçmekte ve bulguları politika yapıcılara aktarılabilir biçimde sunmaktadır (Lundberg & Lee, 2017). Dördüncüsü, SHAP analizinin korelasyon ve örüntü tespitine dayalı yapısının ötesine geçmek amacıyla Nedensel Orman (CausalForestDML) analizi uygulanmıştır. Böylece her değişkenin emisyon üzerindeki nedensel etkisi Ortalama Treatment Etkisi (ATE) çerçevesinde tahmin edilmiştir. Bu sayede bulgular, “ne ilişkili?” sorusundan “ne müdahale edilebilir?” sorusuna cevap vermektedir. Ayrıca, politika yapıcılara nedensel geçerliliği olan araçlar sunulmaktadır (Athey & Imbens, 2016; Chernozhukov vd., 2018). Bu katkılar doğrultusunda çalışma şu araştırma sorularını yanıtlamayı hedeflemektedir:

1. Makine öğrenmesi algoritmaları Türkiye'nin sera gazı emisyon rejimini (düşük ve yüksek emisyon) anlamlı biçimde sınıflandırabilir mi?
2. Hangi makroekonomik ve enerji değişkenleri emisyon rejimini en güçlü biçimde belirlemektedir?
3. Yenilenebilir enerji payı ve GSYİH gibi kilit değişkenlerin emisyon üzerindeki etkisi nedensel çıkarım yöntemleriyle doğrulanabilir mi?

Türkiye'nin 1990-2024 dönemine ait yıllık verileri kullanılarak Gradient Boosting, Random Forest ve Lojistik Regresyon algoritmaları karşılaştırmalı olarak uygulanmıştır. Yüksek korelasyon nedeniyle dolaylı veri sızıntısı riski taşıyan değişkenler sistematik biçimde elenerek modele yalnızca teorik gerekçesi güçlü dört bağımsız değişken dahil edilmiştir: GSYİH, fosil yakıt tüketimi payı, yenilenebilir enerji tüketimi payı ve dış ticaret açıklığı. Çalışmanın geri kalan bölümleri şu şekilde düzenlenmiştir: İkinci bölümde ilgili yazın değerlendirilmekte, üçüncü bölümde veri seti ve

metodoloji sunulmakta, dördüncü bölümde bulgular tartışılmakta, beşinci bölümde ise sonuçlar, politika önerileri ve çalışmanın sınırlılıkları ele alınmaktadır.

Literatür Taraması

Sera gazı emisyonlarının belirleyicilerine yönelik ampirik yazın, teorik temelleri bakımından büyük ölçüde Çevresel Kuznets Eğrisi (ÇKE) hipotezine dayanmaktadır. Grossman ve Krueger (1991) tarafından ticaretin çevresel etkileri bağlamında ortaya konan bu hipotez, kişi başı gelir ile çevre kirliliği arasında ters-U biçimli bir ilişkinin varlığını öngörmektedir. Ekonomik büyümenin belirli bir eşik gelir düzeyine ulaşana kadar çevresel bozulmayı hızlandırdığını, bu eşik aşılmasının ardından ise teknolojik dönüşüm ve yapısal değişim kanalıyla emisyonu azalttığını ileri sürmektedir. Türkiye özelinde bu hipotezi sınanan ilk kapsamlı çalışmalar arasında Halicioğlu (2009) öne çıkmaktadır. Halicioğlu, 1960–2005 dönemine ait yıllık verilerle hata düzeltme modeli ve Granger nedensellik testlerini uygulayarak enerji tüketiminin emisyonun birincil belirleyicisi olduğunu ortaya koymuştur. Ancak çalışma doğrusal eşbütünleşme ilişkisini varsaymakta ve yapısal kırılmaları dikkate almamıştır. Gövdeli (2019), yapısal kırılmaları açıkça dikkate alarak Türkiye için EKC hipotezini ampirik olarak test etmiş, gelir ile çevresel bozulma arasında uzun vadeli bir ilişki olduğunu doğrulamış ve Türkiye örneğinde emisyonların azalmaya başladığı gelir eşikine henüz ulaşılmadığını vurgulamıştır. Bölgesel düzeyde ise Ravanoglu (2020), panel veri analizi kullanarak Avrasya Ekonomik Birliği için EKC hipotezinin geçerliliğini test etmiş ve gelir-emisyon ilişkisinin ülke grupları arasında kurumsal ve yapısal farklılıklar sergilediğine dair karşılaştırmalı kanıtlar sunmuştur. Bu bulgu, mevcut çalışmada benimsenen gibi ülkeye özgü analitik çerçevelerin önemini pekiştirmektedir. Kubar ve Kıl (2022), Türkiye'nin de dahil olduğu "Kırılgan Sekiz" ülke grubu ile G7 ekonomileri için EKC hipotezinin geçerliliğini test etmiş ve gelir-çevre ilişkisinin bu iki grup arasında önemli ölçüde farklılık gösterdiğini ve her bir ekonominin yapısal özelliklerinin emisyon seyrini belirlemede belirleyici bir rol oynadığını ortaya koymuştur. Katırcıoğlu (2014), ARDL sınır testi yaklaşımıyla turizm gelirleri ve enerji tüketiminin uzun dönemli emisyon etkilerini incelemiştir. Bu çalışma da doğrusal model kurgusunun sınırlılıklarından kurtulamamıştır. Pata (2018), FMOLS ve DOLS tahmin edicileriyle yenilenebilir enerji tüketiminin emisyon azaltıcı etkisini istatistiksel olarak doğrulamıştır. Bununla birlikte doğrusal modelleme yapısal heterojenliği yansıtmaktan uzak kalmıştır. Han ve Lin (2025), bu teorik çerçeveyi yorumlanabilir makine öğrenmesi yöntemleriyle yeniden ele alarak her ülkenin kendine özgü koşullarının dikkate alınması gerektiğini göstermiştir. Bu bulgu ülkeye özgü sınıflandırma çerçevelerinin teorik zeminini doğrudan desteklemektedir.

Enerji karması değişkenlerinin emisyon üzerindeki etkisine odaklanan çalışmalar yazının ikinci önemli eksenini oluşturmaktadır. Apergis ve Payne (2009), panel veri yöntemiyle 16 gelişmekte olan ekonomi için yenilenebilir enerji tüketimi ile emisyon arasında uzun dönemli negatif bir ilişki tespit etmiştir ve bu ilişkinin kısa dönemde zayıf kaldığını göstermiştir. Shafiei ve Salim (2014), OECD ülkelerine yönelik panel analizlerinde fosil yakıt tüketiminin emisyonu artırırken yenilenebilir enerjinin belirgin bir azaltıcı etki ürettiğini ortaya koymuştur. Dış ticaret açıklığının emisyon üzerindeki etkisi ise kirlilik sığınağı hipotezi çerçevesinde tartışılmaktadır. Benzer bir bağlamda, Yılmaz (2020) CO₂ emisyonları ile doğrudan yabancı yatırımlar, insani gelişme endeksi ve teknoloji arasındaki ilişkiyi analiz etmiş ve teknolojik ilerlemenin ve insani gelişmenin emisyonların azaltılmasına katkıda bulunduğunu, buna karşın doğrudan yabancı yatırımların rolünün bağlama bağlı olduğunu ortaya koymuştur. Bu bulgu, mevcut çalışmanın çok değişkenli çerçevesine teorik bir dayanak sağlamaktadır. Özellikle Türkiye bağlamında, Özen ve ark. (2024), insani gelişme, kentleşme, endüstriyel gelişme, tarımsal gelişme ve karbon emisyonları arasındaki ilişkileri incelemiş ve emisyonların çok boyutlu yapısal etkenlerinin tek bir değişkene indirgenemeyeceğini doğrulamıştır. Bu bulgu, bu çalışmanın çok değişkenli tasarımıyla doğrudan tutarlıdır. Bu çalışmayla aynı N-11 ülke grubuna odaklanan Açıkgöz ve Öncel (2024), ekonomik büyüme, fosil yakıt tüketimi ve küreselleşmenin çevresel bozulma üzerindeki etkilerini ülke bazında incelemiş ve bu etkilerde ülkeler arasında önemli bir heterojenlik tespit etmiştir. Bu sonuç, burada

benimsenen ülkeye özgü sınıflandırma tasarımı desteklemektedir. Cole (2004), gelişmekte olan ülkelerde çevre standartlarının görece düşüklüğünün kirli endüstrilerin bu ülkelere yönelmesine zemin hazırladığını ve emisyon transferi etkisi yarattığını göstermiştir. Çoşgun (2024) ve Çınarer vd. (2024), Türkiye'de GSYİH ve nüfus gibi ekonomik değişkenlerin emisyonlarla 0,92–0,98 aralığında yüksek korelasyon sergilediğini vurgulamıştır. Bu bulgu mevcut çalışmada GSYİH'nın bağımsız değişken olarak dahil edilmesine doğrudan teorik destek sağlamaktadır.

Makine öğrenmesi yöntemlerinin emisyon tahminine uygulanması görece yakın bir tarihe dayanmakla birlikte son yıllarda hızla genişleyen bir alan haline gelmiştir. Breiman (2001) rassal orman algoritmasını, Friedman (2001) gradient boosting yöntemini tanıtarak bu algoritmaların doğrusal olmayan ilişkilerdeki üstün performansını teorik ve ampirik düzlemde ortaya koymuştur. Türkiye odaklı makine öğrenmesi çalışmaları incelendiğinde, Ağbulut (2022) ulaştırma kaynaklı enerji talebini ve CO_2 emisyonlarını derin öğrenme, SVM ve yapay sinir ağlarıyla modellemiştir. Bu çalışma, Türkiye'nin ulaştırma sektörü için söz konusu algoritmaları kullanan ilk kapsamlı araştırma olma özelliği taşımaktadır. Ayaz (2024), 1865–2023 yıllarını kapsayan geniş bir veri setiyle ARIMA (%94,3 R^2) ve LSTM (%90,4 R^2) modellerini karşılaştırmıştır. Çalışma, geleneksel zaman serisi modellerinin uzun dönemli bağımlılıklarda rekabetçi performans sergilediğini göstermiştir. Rufaioğlu vd. (2025), 2012–2021 dönemine ait sera gazı verileriyle Gradient Boosting ($R^2 = 0,995$) ve XGBoost ($R^2 = 0,994$) algoritmalarının en yüksek doğruluğa ulaştığını tespit etmiştir. Ene Yalçın (2024), enerji, endüstriyel süreçler, tarım ve atık sektörlerini kapsayan çok sektörlü bir çerçevede doğrusal regresyon modelini uygulamıştır. Beken vd. (2019) ise k-Ortalamalar Kümeleme algoritmasıyla Türkiye'nin Avrupa ülkeleriyle enerji verimliliği karşılaştırmalarını gerçekleştirmiştir. Uluslararası yazında Bakır vd. (2022) Hindistan; Javanmard & Ghaderi (2022) İran; Bhatt vd. (2023) ABD ve Hasan vd. (2025) Bangladeş verileriyle yürüttükleri çalışmalarda hibrit optimizasyon ve topluluk modellerinin küçük veri setlerinde daha kararlı sonuçlar ürettiğini ortaya koymuştur.

Model değerlendirme ve yorumlanabilirlik boyutunda ise Leerbeck vd. (2020), güç şebekelerindeki CO_2 emisyon yoğunluğunu makine öğrenmesiyle modelleyerek veri kalitesi ve miktarının artmasıyla bu alanın önemli bir potansiyel barındırdığını vurgulamıştır. Jin ve Sharifi (2025), yorumlanabilirlik araçlarının özellikle SHAP değerlerinin, emisyon modellemesinde giderek daha fazla benimsenmesinin politika öneri açısından kritik önem taşıdığını göstermiştir. Lundberg ve Lee (2017) tarafından geliştirilen SHAP çerçevesi, iş birliği teorisinden türetilen Shapley değerlerini makine öğrenmesi modellerine uyarlayarak her bir değişkenin bireysel katkısını tutarlı, yerel ve küresel düzeyde ölçme imkânı sunmaktadır. Strobl vd. (2007) ve Lundberg vd. (2020), Gini safsızlık azaltması tabanlı değişken önem ölçütünün diğer değişkenlerle korelasyonlu değişkenleri abartma eğiliminde olduğunu göstermiştir. Bu bulgu mevcut çalışmada değişken önem analizinin SHAP değerleriyle birlikte sunulmasına ilişkin metodolojik tercihin gerekçesini oluşturmaktadır.

Nedensel çıkarım yöntemlerinin emisyon araştırmalarına uygulanması görece yeni bir alandır. Pearl (2009), nedensel modelleme çerçevesini istatistiksel bağımlılıktan nedensel ilişkilere geçişin teorik zeminini oluşturacak biçimde ortaya koymuştur. Yapısal nedensel modeller aracılığıyla gözlemsel veriden müdahale etkisinin nasıl tahmin edileceğini göstermiştir. Athey ve Imbens (2016), rassal orman algoritmasını nedensel bağlama uyarlayarak geliştirdikleri Nedensel Orman (Causal Forest) yöntemiyle heterojen “treatment” etkilerinin tarafsız biçimde tahmin edilebildiğini kanıtlamıştır. Wager ve Athey (2018), bu yöntemi daha ileri götürerek tutarlılık ve asimptotik normallik özelliklerini kuramsal olarak ispat etmiştir. Söz konusu yöntemin emisyon araştırmalarına uygulanması, SHAP analizinin yanıtlayamadığı “hangi değişkende gerçekleştirilecek bir politika müdahalesi emisyonu azaltır?” sorusunu doğrudan ele alma imkânı sunmaktadır. Türkiye odaklı makine öğrenmesi çalışmalarında bu tür nedensel çıkarım yaklaşımlarına rastlanmamış olması, mevcut çalışmanın bu yöntemi entegre etmesini yazın açısından özgün kılmaktadır.


Yukarıda derlenen yazın dört temel metodolojik boşluğa işaret etmektedir. Birincisi, Türkiye odaklı makine öğrenmesi çalışmalarının tamamına yakını regresyon tabanlı sürekli tahmin problemlerine odaklanmaktadır. Konu, sınıflandırma problemi olarak ele alınmamıştır. İkincisi, mevcut çalışmalarda model yorumlanabilirliği sistematik biçimde raporlanmamaktadır. Bu durum bulguların politika süreçlerine aktarımını güçleştirmektedir. Üçüncüsü, küçük örneklem koşullarına özgü doğrulama yöntemlerine özellikle LOO-CV çalışmalarına Türkiye yazınında rastlanmamıştır. Dördüncüsü, mevcut çalışmaların hiçbirinde SHAP analizinin nedensel çıkarım yöntemiyle sistematik biçimde birleştirilmediği görülmektedir. Korelasyon ve tahmin gücü yüksek bir değişkenin politika müdahalesine gerçekten yanıt verip vermeyeceği sorusu yanıtsız kalmaktadır. Bu çalışma Nedensel Orman analizini entegre ederek bu dördüncü boşluğu da gidermeyi hedeflemektedir³.

Metodoloji

Bu çalışmada geleneksel ekonometrik yöntemlerin sınırlarını aşmak amacıyla modern ve nesnel bir yöntem izlenmiştir. Bu amaçla makine öğrenmesi algoritmaları ve açıklanabilir yapay zeka (XAI) teknikleri sistematik biçimde bir arada uygulanmıştır. Modelleme süreci tek bir teorik çerçeve ya da kısıtlı bir değişken setiyle sınırlandırılmamıştır. Teorik gerekçesi güçlü değişkenlerden oluşan çok boyutlu bir yapı üzerine inşa edilerek daha yansız ve veri odaklı bir yaklaşım benimsenmiştir. Geleneksel regresyon tabanlı yöntemlerde sıklıkla karşılaşılan model varsayımı ihlalleri, endojenlik ve doğrusal olmayan etkileşimleri yakalayamama gibi kısıtları aşmak amacıyla topluluk öğrenmesi (ensemble learning) algoritmaları kullanılmıştır. Çalışmada benimsenen hibrit yapı hem tahmin doğruluğunu artırmakta hem de model sonuçlarını politika yapıcılara aktarılabilir biçimde açıklanabilir kılmaktadır. Bu metodolojik birleşim, kolektif öğrenme, açıklanabilir yapay zeka ve nedensel orman, Sert (2026) tarafından da yapılan çalışmada kullanılmıştır. Yazar, küresel gelir eşitsizliğinin belirleyicilerini incelemek için bu entegre çerçeveyi uygulamış ve ensemble algoritmaları, SHAP tabanlı açıklanabilirlik ile nedensel orman çıkarımının bir araya getirilmesinin, tek başına uygulanan herhangi bir yöntemden çok daha zengin politika içgörülerini sağladığını ortaya koymuştur. Bu son özellik, Gradient Boosting ve Random Forest gibi kara kutu niteliğindeki topluluk algoritmalarının SHAP (SHapley Additive exPlanations) ve nedensel orman (Causal Forest) çerçevesiyle yorumlanmasıyla sağlanmıştır (Lundberg & Lee, 2017; Athey & Imbens, 2016). Bu bölümde veri seti kapsamlı biçimde tanıtılmakta ve metodolojik adımlar ayrıntılı olarak açıklanmaktadır. Çalışmada izlenen metodoloji Şekil 1'de sunulmaktadır.⁴

³ İklim değişikliğinin çevresel, ekonomik, toplumsal ve kültürel boyutlarını doğrudan veya ilişkili temalar üzerinden ele alan; göl seviyeleri, meteorolojik ve hidrometeorolojik afetler, biyoklimatik konfor, hava kalitesi, tarımsal verimlilik ve arazi örtüsü değişimleri; karbon emisyonları, fosil yakıt tüketimi, iklim müzakereleri, karbon sertifikaları ve ülkelerin iklim koruma performansları; yenilenebilir enerji eğitimi, binalarda ve ibadet mekânlarında enerji verimliliği, ekolojik mimarlık, dirençli kentsel hareketlilik ve sıfır atık yönetimi; sivil toplumun çevre bilincine katkısı, küreselleşme, ekolojik sanat, sürdürülebilir seramik ve tekstil uygulamaları, edebiyatta doğa-insan ilişkisi, popüler medyada çevresel sürdürülebilirlik temsilleri ve dinî değerler bağlamında sürdürülebilir kalkınma üzerine yapılan çalışmalar için ayrıca bk. Bahadır, 2012; Erdoğan & Ganiev, 2016; İçel, 2014; Karataş, 2014; Pınarcıoğlu, 2018; Ulusoy & Atay, 2018; Altıntaş, 2021; Aytepe Serinsu, 2022; Menteşe & Koca, 2025; Akdağ & Parlak Biçer, 2025; Kayaalp & Gürbüz, 2025; Sağır & Çakır, 2026; Doğru & Demirbaş, 2020; İrdem, 2022; Kazel, 2022; Korkmazıyürek et al., 2022; Aytekin & Ateş, 2019; Demir & Süslü, 2022; Süar Oral, 2021; Gökçe & Gökçe, 2020; Aldoori & Benchalel, 2026.

⁴ Bu literatürle birlikte yapay zeka uygulamaları sosyal bilimlerde hem inceleme alanı olmuş hem de araştırma metodolojinde önemli bir konuma gelmiştir. Örnek olması bakımından bk. Denizci et al. 2018, Baran 2022, Keleş & Keleş, 2018; Karadağ, 2025; Coşkun, 2025; Ahmed & Hamod, 2026; Arıcı & Karacı, 2013; Keleş & Keleş, 2017; Keleş et al., 2017; Bekil, 2018; Keleş, 2018; Serçemeli, 2018; Akyıldız & Akyıldız, 2020; Işık & Darı, 2023; Abdulrazagova et al., 2025; Arğin 2025; Tetik Küçükkelçi, 2025; Çakmak, 2025; Yıldırım Altun, 2025; Zan & Zan, 2025; Mazlum & Mazlum, 2025; Yıldız, 2025; Başar, 2025; Tuğcu, 2025; Özdemir, 2026; Çora et al., 2026; Büyükboyacı & Yozcu, 2026; Ardatürk, 2026; Arduç Kara, 2026; Ertan, 2026; Ahmed & Hamod, 2026; Efendioğlu, 2023; Çelik et al., 2025; Doğru & Hacımuftuoğlu, 2025; Koçakoğlu & Koçakoğlu, 2025; Ekinci, 2025; Sakin & Türk, 2025; Aşkun, 2024; Yener & Köse, 2023; Romya Bilgin & Küçükşabanoğlu, 2023; Çark, 2020; Kanat, 2020; Altundış, 2020; Zenginaloğlu, 2026; Dalmış, 2026; Ölçer, 2025; Sarıbaş, 2025; Karakuş et al., 2025; Güzel, 2024; Kızıldağ, 2023; Odacıoğlu, 2022; Erdem-Demiryakan



Şekil 1: Çalışma Metodolojisi

Kaynak: Yazarlar tarafından hazırlanmıştır.

Veri seti

Çalışmada, Türkiye'nin 1990-2024 dönemine ait 35 yıllık veriler kullanılmıştır. Bağımlı değişken olan toplam sera gazı emisyonu TÜİK Sera Gazı Emisyon İstatistiklerinden, bağımsız değişkenler ise Dünya Bankası Açık Veri Tabanından derlenmiştir. Analizde kullanılan değişkenler Tablo 1'de sunulmaktadır.

Tablo 1: Değişkenler, Tanımlar ve Kaynaklar

Değişken	Tanım	Kaynak
Sera Gazı	Toplam sera gazı emisyonu (Mt CO ₂ eşd.)	TÜİK
GSYİH	Kişi başı gayrisafi yurt içi hasıla (cari USD)	Dünya Bankası
Fosil Yakıt	Toplam enerji tüketiminde fosil yakıt payı (%)	Dünya Bankası
Yenilenebilir Enerji	Toplam nihai enerji tüketiminde yenilenebilir enerji payı (%)	Dünya Bankası
Dış Ticaret Açıklığı	Dış ticaret hacminin GSYİH'ya oranı (%)	Dünya Bankası

GSYİH, ÇKE hipotezinin temel açıklayıcı değişkeni olarak modele dahil edilmiştir (Grossman & Krueger, 1991). Fosil yakıt payı ve yenilenebilir enerji payı, enerji karmasının emisyon üzerindeki yapısal etkisini temsil etmektedir (Shafiei & Salim, 2014). Dış ticaret açıklığı ise kirlilik sığınağı hipotezi çerçevesinde modele eklenmiştir (Cole, 2004).


Çalışmanın başlangıç aşamasında değişken havuzuna sanayi üretim endeksi, motorlu kara taşıtı sayısı ve kentleşme oranı da dahil edilmiştir. Ancak bu değişkenlerin sera gazı emisyonuyla Pearson korelasyon katsayılarının sırasıyla 0,981, 0,985 ve 0,981 olduğu; ayrıca sanayi üretim endeksi ile araç sayısı arasındaki korelasyonun 0,993 düzeyine ulaştığı tespit edilmiştir. Bu durum çoklu doğrusal bağlantı problemi yaratmakta (Gujarati & Porter, 2009; Hair vd., 2010) ve ML algoritmasını manipüle etmektedir. Başka bir ifade ile söz konusu değişkenlerin sera gazı emisyonunu açıklayan bağımsız bir bilgi içermediğini, aksine emisyonu doğrudan temsil eden vekil

2025, Civelek 2025, Günay 2025, Önen 2025, Özdemir 2025; Sandıkcı & Soy 2026; Arduç Kara 2026; Ertan 2026; Uygun 2026; Yılmaz 2025; Kan Çelik 2026; Bayat Arslan & Cuma 2026; Köksal & Zorlu Kale 2025; Varol 2025; Ahmed & Hamod 2026; Efendioğlu 2023; Sert 2026; Güçlüten 2026.

değişkenler niteliği taşıdığını ortaya koymaktadır. Makine öğrenmesi modellerinde hedef değişkenle neredeyse deterministik ilişki içindeki vekil değişkenlerin kullanılması, modelin gerçek belirleyicileri öğrenmek yerine bu ilişkiyi ezberlemesine yol açmaktadır. Bu durum, literatürde vekil sızıntısı (surrogate leakage) olarak adlandırılmaktadır (Kaufman vd., 2012). Bu nedenle söz konusu üç değişken analizden çıkarılmıştır. Modelde yalnızca teorik gerekçesi güçlü ve birbirinden görece bağımsız dört açıklayıcı değişken kullanılmıştır.

Tanımlayıcı İstatistikler ve Korelasyon Analizi

Analiz döneminde Türkiye'nin yıllık sera gazı emisyonu 228,9 Mt (1990) ile 584,5 Mt (2024) arasında seyretmiştir. Bu otuz beş yıllık süreçte yaklaşık 2,55 katlık bir artışın olduğu gözlenmiştir (Şekil 2).



Şekil 2. Sera Gazı Emisyon Değerleri (1990-2024)

Şekil 2'de yüksek emisyon rejimine geçişi belirten eşik değerine göre düşük ve yüksek emisyon dönemleri gösterilmiştir. Analizde kullanılan değişkenlere ilişkin tanımlayıcı istatistikler Tablo 2'de sunulmaktadır.


Tablo 2: Tanımlayıcı İstatistikler (1990–2024)

Değişken	Ortalama	Std. Sapma	Min	Maks
Sera Gazı (Mt)	389,7	116,4	228,9	584,5
GSYİH (USD)	7708	3876	2176	15893
Fosil Yakıt (%)	86,88	2,54	82,2	91,4
Yenilenebilir En. (%)	16,28	4,44	11,4	24,4
Dış Ticaret Açıklığı (%)	49,0	11,09	30,5	79,9

Emisyon serisinin standart sapması (116,4 Mt) ortalamasının yaklaşık %30'una karşılık gelmektedir. Bu değer dönem içinde emisyon yörüngesinin yüksek bir değişkenlik sergilediğini göstermektedir. Fosil yakıt payının yüksek ortalama (%86,88) ve görece düşük standart sapma (2,54 puan) ile seyretmesi, Türkiye'nin enerji karmasındaki yapısal katılığı yansıtmaktadır. Yenilenebilir enerji payındaki standart sapma (4,44 puan) ise bu değişkenin dönem içinde anlamlı bir dönüşüm geçirdiğine, dolayısıyla model açısından açıklayıcı potansiyel taşıdığına işaret etmektedir.

Analizde kullanılan değişkenler arasındaki korelasyon yapısı Şekil 3'te sunulmaktadır. Dört değişken arasındaki korelasyon katsayılarının, çoklu doğrusallık için kritik eşik değer olarak kabul edilen $|r| = 0,90$ sınırının (Gujarati & Porter, 2009; Hair vd., 2010) büyük ölçüde altında kaldığı görülmektedir. En yüksek korelasyon, GSYİH ile yenilenebilir enerji payı arasında negatif yönde

($r = -0,90$) gözlemlenmiştir. Bu ilişki, ekonomik büyüme sürecinde enerji talebinin arttığı ve yenilenebilir enerji payının görece gerilediği yapısal bir örüntüyü yansıtmaktadır. Fosil yakıt payı ile yenilenebilir enerji payı arasındaki negatif korelasyon ($r = -0,88$) ise enerji karmasındaki ikame ilişkisinin beklenen teorik yönünü doğrulamaktadır.



Şekil 3. Değişkenlere İlişkin Pearson Korelasyon Katsayıları

Eksik Veri Yönetimi

Ham veri setinde iki temel eksiklik tespit edilmiştir. Fosil yakıt tüketimi verisi 2016 - 2021 dönemini kapsayan altı gözlem için Dünya Bankası veri tabanında raporlanmamıştır. Bu eksikliğin veri raporlama sürecindeki gecikmeden kaynaklandığı değerlendirilmektedir. Yenilenebilir enerji payı verisi ise 2022–2024 yılları için henüz kesinleşmemiştir. Her iki eksiklik de doğrusal enterpolasyon (linear interpolation) yöntemiyle giderilmiştir. Veri setinin uç noktalarındaki eksiklikler için geri doldurma (backfill) ve ileri taşıma (forward fill) yöntemleri uygulanmıştır. Tamamlama işlemi sonrasında veri setinde eksik gözlem kalmamıştır.

Hedef Değişkenin Oluşturulması

Makine öğrenmesi tabanlı sınıflandırma analizinin uygulanabilmesi için sürekli yapıdaki sera gazı emisyonu değişkeninin kategorik bir hedef değişkene dönüştürülmesi gerekmektedir. Bu sebeple bağımlı değişken olan sera gazı emisyonları (Mt), medyan değeri (395,9 Mt) esas alınarak ikili sınıfa dönüştürülmüştür. Medyanın altında kalan gözlemler düşük emisyon (sınıf 0), medyan ve üzerindeki gözlemler ise yüksek emisyon (sınıf 1) olarak kodlanmıştır. Bu operasyonelleştirme kararının temel gerekçesi istatistikseldir. Sera gazı emisyonları gibi sağa çarpık dağılım sergileyen değişkenlerde ortalama tabanlı bir eşik aykırı gözlemlere karşı duyarlıyken, medyan tabanlı eşik dağılımdan bağımsız ve aykırı değerlere karşı dayanıklı bir bölünme noktası sunmaktadır (Terzioğlu vd., 2026). Söz konusu tercih 17 düşük emisyon ve 18 yüksek emisyon gözleminden oluşan yaklaşık 1:1 oranında dengeli bir sınıf dağılımı üretmekte; He ve Garcia'nın (2009) ciddi dengesizlik eşiği olarak tanımladığı 4:1 oranının çok altında kalmaktadır. Bu denge, küçük örneklerde ($n = 35$) sınıf dengesizliğine bağlı önyargı riskini yapısal olarak ortadan kaldırmakta ve F1 skoru optimizasyonu ile çapraz doğrulama sürecinin güvenilirliğini pekiştirmektedir. Medyan eşiği normatif bir emisyon hedefini değil, örneklem içi göreceli performansı temsil etmekte olup sektörden bağımsız, yorumlanabilir bir kıyaslama noktası sağlamaktadır (Terzioğlu vd., 2026).

Makine Öğrenmesi Algoritmaları

Bu çalışmada üç sınıflandırma algoritması karşılaştırmalı olarak uygulanmıştır. Algoritma seçiminde iki temel ölçüt belirleyici olmuştur: küçük örneklem koşullarında kararlı performans ve model yorumlanabilirliğine elverişlilik.

Gradient Boosting (GB), Friedman (2001) tarafından geliştirilen bir topluluk öğrenmesi yöntemidir. Algoritma, ardışık olarak eğitilen zayıf öğrencilerin (karar ağaçlarının) bir araya getirilmesine dayanmaktadır. Her yeni ağaç, bir öncekinin artık hatasını (residual) minimize etmektedir. t -inci adımda model Formül 1 ile güncellenir:

$$F_t(x) = F_{t-1}(x) + \eta \cdot h_t(x) \quad (1)$$

Burada $F_{t-1}(x)$ önceki adımın tahmin fonksiyonunu, $h_t(x)$ yeni zayıf öğrencinin katkısını ve η öğrenme hızını (learning rate) ifade etmektedir. Kayıp fonksiyonunun gradyanı yönünde gerçekleştirilen bu güncelleme, değişkenler arasındaki doğrusal olmayan ilişkileri ve yüksek dereceli etkileşimleri modelleyebilme kapasitesi sağlamaktadır.

Rassal Orman (Random Forest - RF), Breiman (2001) tarafından önerilen bir bagging (bootstrap aggregating) topluluğudur. B adet karar ağacı, her seferinde orijinal veri setinden yinelenmeli örneklemeyle (bootstrap) oluşturulan alt kümeler üzerinde eğitilmektedir. Her ağaçta rastgele seçilen bir özellik alt kümesi kullanılmaktadır. Sınıflandırma kararı çoğunluk oylamasıyla elde edilmektedir (Formül 2):

$$\hat{y} = \arg \max_k \sum_{b=1}^B 1 [h_b(x) = k] \quad (2)$$

Her ağacın rastgele özellik alt kümesi üzerinde eğitilmesi, bireysel ağaçlar arasındaki korelasyonu kırarak topluluğun varyansını düşürmekte ve genelleme gücünü artırmaktadır. Rassal Orman algoritması, ağaç tabanlı yapısı sayesinde değişkenler arasındaki doğrusal olmayan ilişkileri ve yüksek dereceli etkileşimleri modelleyebilmektedir. Bootstrap örneklemesine dayalı torbalama (bagging) stratejisi ve her bölmede rastgele seçilen özellik alt kümeleri, bireysel ağaçlar arasındaki korelasyonu kırarak topluluğun varyansını düşürmekte ve modelin aşırı öğrenmeye (overfitting) karşı yapısal bir direnç geliştirmesini sağlamaktadır (Breiman, 2001).

Lojistik Regresyon (LR), doğrusal karar sınırı varsayımına dayanan parametrik bir sınıflandırıcıdır. İkili sınıflandırma için lojistik (sigmoid) fonksiyonu aracılığıyla sınıf olasılığı şu şekilde modellenmektedir (Formül 3):

$$P(y = 1 | x) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)}} \quad (3)$$

Bu çalışmada LR hem doğrusal bir başlangıç kıyası (baseline) olarak hem de doğrusal olmayan yöntemlerin sunduğu ek değer in ölçülebilmesi amacıyla modele dahil edilmiştir.

Ön İşleme ve Veri Sızıntısı Kontrolü

Tüm sayısal özellikler Z-skoru standardizasyonuna (Formül 4) tabi tutulmuştur:

$$z = \frac{x - \mu}{\sigma} \quad (4)$$

Standardizasyon parametreleri (μ ve σ) yalnızca eğitim verisi üzerinde hesaplanmış; test verisine bu parametreler dışarıdan uygulanmıştır. Bu uygulama, test setinden eğitim setine bilgi

sızıntısını yapısal olarak engellemektedir. Tüm ön işleme ve modelleme adımları scikit-learn Pipeline yapısı içinde zincirlenerek her doğrulama katı için bağımsız biçimde yeniden uygulanmıştır.

Hiperparametre Optimizasyonu

Her algoritmanın hiperparametreleri, ızgara arama (GridSearchCV) yöntemiyle optimize edilmiştir. Optimizasyon sürecinde iç doğrulama düzeneği olarak tabakalı 5-katlı çapraz doğrulama (Stratified 5-Fold CV) kullanılmıştır. Böylelikle her katta her iki sınıfın orantılı temsili güvence altına alınmıştır. Skor ölçütü olarak sınıf dengesizliğine duyarlı F1 skoru benimsenmiştir. Gradient Boosting için öğrenme hızı (η), ağaç derinliği ve ağaç sayısı; Random Forest için ağaç sayısı, maksimum derinlik ve minimum dal bölme eşiği; Lojistik Regresyon için düzenleme parametresi C ve çözümci seçimi optimize edilmiştir.

Model Değerlendirme: Bırak-Bir-Dışarıda Çapraz Doğrulama

Bu çalışmada birincil model değerlendirme yöntemi olarak bırak-bir-dışarıda çapraz doğrulama (Leave-One-Out Cross-Validation, LOO-CV) kullanılmıştır. n gözlemden oluşan bir veri setinde LOO-CV, her tekrarda yalnızca bir gözlemi test seti olarak ayırıp geriye kalan $n - 1$ gözlem üzerinde modeli yeniden eğitmektedir. Bu işlem tüm n gözlem için tekrarlanmaktadır. LOO-CV tahmin hatası Formül 5 ile hesaplanmaktadır:

$$\text{LOO-CV Hatası} = \frac{1}{n} \sum_{i=1}^n L(y_i, \hat{f}^{(-i)}(x_i)) \quad (5)$$

Burada $\hat{f}^{(-i)}$, i -inci gözlem dışarıda bırakılarak eğitilen modeli, L ise kayıp fonksiyonunu ifade etmektedir. Bu çalışmada $n = 35$ olup standart 5-katlı CV'de her test kümesi yalnızca 7 gözlem içermektedir. Bu durum değerlendirme varyansını yükseltmekte ve performans tahminlerini istikrarsız kılmaktadır. LOO-CV ise her tekrarda $n - 1 = 34$ gözlemlik eğitim kümesiyle çalışarak tahmin yanlılığını en aza indirmektedir. Arlot ve Celisse (2010), küçük örneklem boyutlarında LOO-CV'nin standart k -katlı yöntemlere kıyasla daha düşük yanlılıklı tahminler ürettiğini kuramsal olarak göstermiştir.

Model performansı; doğruluk (accuracy), kesinlik (precision), duyarlılık (recall) ve F1 skoru ölçütleriyle değerlendirilmiştir. Sınıf dengesizliği göz önünde bulundurulduğunda birincil ölçüt olarak harmonik ortalama olan F1 skoru benimsenmiştir (Formül 6):

$$F1 = 2 \cdot \frac{\text{Kesinlik} \times \text{Duyarlılık}}{\text{Kesinlik} + \text{Duyarlılık}} \quad (6)$$

Model Yorumlanabilirliği: SHAP Analizi

Makine öğrenmesi modelleri, tahmin gücü yüksek olmakla birlikte genellikle kara kutu niteliği taşımaktadır. Bu durum, hangi değişkenlerin hangi yönde ve ne ölçüde modele katkı sağladığının anlaşılmasını güçleştirmektedir. Söz konusu kısıtı aşmak amacıyla ekonomi ve politika yazınında açıklanabilir yapay zeka (Explainable Artificial Intelligence - XAI) tekniklerine başvurulmaktadır (Gunning & Aha, 2019). Bu çalışmada XAI tekniklerinden SHAP (SHapley Additive exPlanations) yöntemi kullanılmıştır.

Oyun teorisinin temel kavramlarından Shapley değerlerine dayanan SHAP, her bir değişkenin modelin tahmin çıktısına marjinal katkısını tüm olası değişken kombinasyonları üzerinden hesaplamaktadır (Lundberg & Lee, 2017). i -inci gözlem için j -inci özelliğin SHAP değeri Formül 7 ile tanımlanmaktadır:

$$\phi_j(i) = \sum_{S \subseteq F \setminus \{j\}} \frac{|S|! (|F| - |S| - 1)!}{|F|!} [f_{S \cup \{j\}}(x_i) - f_S(x_i)] \quad (7)$$

Burada F tüm özellikler kümesini, S özelliği dışındaki herhangi bir alt kümeyi, $f_S(x_i)$ ise yalnızca S kümesindeki özelliklerle tahmin edilen modeli ifade etmektedir. Modelin toplam tahmin değeri, tüm değişkenlere ait marjinal katkıların toplamıyla elde edilmektedir. SHAP değerleri etkinlik ($\sum_j \phi_j = f(x) - E[f(x)]$), simetri ve kukla değişken aksiyomlarını sağlamaktadır. Bu sayede değişkenlerin katkısını tutarlı, yerel ve küresel düzeyde ölçmektedir.

Bununla birlikte SHAP, diğer XAI teknikleri gibi yalnızca değişkenlerin tahmin üzerindeki katkısını ölçmektedir. Bu katkının nedensel bir ilişkiye karşılık gelip gelmediğini garanti edememektedir (Adadi & Berrada, 2018; Molnar, 2022). Değişken önem analizi ile SHAP arasındaki olası sıralama farklılıkları ise Gini safsızlık azaltması ölçütünün korelasyonlu değişkenleri abartma eğiliminden kaynaklanabileceğinden (Strobl vd., 2007; Lundberg vd., 2020), bu çalışmada SHAP bulguları birincil yorumlama referansı olarak alınmıştır.

Nedensel Orman Analizi

SHAP analizinin nedensellik garantisi vermediği göz önünde bulundurulduğunda, değişkenlerin sera gazı emisyonu üzerindeki gerçek nedensel etkilerini tahmin etmek amacıyla nedensel çıkarım yöntemlerine başvurulmuştur (Neuberg, 2003). Nedensel çıkarımda asıl amaç, bir değişken bir birim değiştiğinde bunun bağımlı değişken üzerinde yarattığı etkiyi izole etmektir. Bu doğrultuda Athey ve Imbens (2016) tarafından geliştirilen ve klasik rassal orman algoritmasını nedensel bağlama uyarlayan Nedensel Orman (Causal Forest) yöntemi kullanılmıştır.

Nedensel Orman'ın temel özelliği, ağaç yapısının dallanma kriterlerini tahmin hatasını minimize etmeye değil, değişkenin koşullu ortalama “treatment” etkisindeki farklılıkları maksimize etmeye göre belirlenmesidir. Buna ek olarak kullandığı veri ayırma stratejisi (honesty), ağaç bölme kurallarının belirlenmesinde bir alt küme, etkilerin tahmin edilmesinde ise diğer alt küme kullanılarak aşırı öğrenme riskini yapısal biçimde azaltmaktadır (Wager & Athey, 2018). Bu sayede doğrusal varsayımlara gerek kalmadan karmaşık ve doğrusal olmayan nedensel ilişkiler modellenabilmektedir.

Bu çalışmada nedensel orman analizi Microsoft EconML kütüphanesinin CausalForestDML algoritmasıyla uygulanmıştır. Çift makine öğrenmesi (Double Machine Learning - DML) çerçevesine dayanan bu yaklaşımda hem çıktı hem de “treatment” modelleri için Gradient Boosting tahmin edicileri kullanılmış, gözlemlenebilir karıştırıcı değişkenlerin (confounders) etkisi sistematik biçimde arındırılmıştır (Chernozhukov vd., 2018). SHAP analizi sonucunda yüksek katkı değerine sahip olduğu belirlenen değişkenler sırayla “treatment” değişkeni olarak tanımlanmıştır. Her seferinde geri kalan değişkenler koşullu tutularak ilgili değişkenin marjinal nedensel etkisi tahmin edilmiştir. Yöntem, gözlemlenebilir karıştırıcıların modele dahil edildiği koşullu bağımsızlık ve yeterli örtüşme (overlap) varsayımları altında yorumlanmaktadır. Bu çalışmada ortalama treatment etkisi (Average Treatment Effect - ATE) hesaplanmıştır.

Bulgular

Bu bölümde, Türkiye'nin 1990–2024 dönemi sera gazı emisyonu verilerine uygulanan makine öğrenmesi tabanlı sınıflandırma analizinin bulguları sunulmaktadır. Sırasıyla hiperparametre optimizasyonu sonuçları, LOO-CV model performansı, konfüzyon matrisi, değişken önem analizi, SHAP analizi ve Nedensel Orman analizi ele alınmaktadır. Bulgular, hem modellerin tahmin başarısını hem de emisyon belirleyicilerinin yön ve büyüklüğünü ortaya koymaktadır.

Her üç algoritmanın optimal hiperparametreleri ızgara arama ve tabakalı 5-katlı çapraz doğrulama ile belirlenmiştir. Optimizasyon sonuçları Tablo 3'te gösterilmektedir.

Tablo 3. Hiperparametre Optimizasyonu Sonuçları (Tabakalı 5-Katlı CV)

Model	Optimal Parametreler	CV5 F1	CV5 Std
Gradient Boosting	lr=0,05, depth=2, n=100	1,000	0,000
Rassal Orman	depth=None, split=2, n=100	0,971	0,057
Lojistik Regresyon	C=1, solver=lbfgs	0,971	0,057

Tablo 3 incelendiğinde Rassal Orman ve Lojistik Regresyonun aynı, Gradient Boosting algoritmasının ise daha yüksek CV5 F1 profilleri sergilediği görülmektedir. Gradient Boosting, öğrenme hızı 0,05, maksimum ağaç derinliği 2 ve ağaç sayısı 100 olarak belirlenen optimal parametrelerle CV5 F1 = 1,000 değerine ulaşmıştır. Standart sapmanın sıfır olması, beş katlı çapraz doğrulamanın her katında mükemmel sınıflandırma elde edildiğini göstermektedir. Bu sonuç, medyan eşiğinin sağladığı ~1:1 sınıf dengesi ile düşük derinlikli ağaç yapısının (depth=2) küçük veri setinde birlikte işlev görmesinden kaynaklanmaktadır. Bununla birlikte CV5 değerlendirmesinin 7 gözlemlilik test kümeleri üzerinden yapıldığı ve dolayısıyla iyimser bir performans tahmini üretebileceği göz önünde bulundurulmalıdır. Nitekim LOO-CV değerlendirmesinde GB F1 = 0,971'e gerilemekte, bu da CV5'in aşırı iyimserliğini açıkça ortaya koymaktadır. Rassal Orman ve Lojistik Regresyon eşit CV5 F1 skoru (0,9714) elde etmiştir. Her iki modelin standart sapmasının 0,0571 düzeyinde kalması, farklı eğitim alt kümeleri karşısında tutarlı ama mükemmel olmayan bir öğrenme davranışına işaret etmektedir. Bu örüntü metodolojik açıdan daha güvenilir bir genelleme kapasitesinin göstergesidir. Optimal parametreler incelendiğinde Random Forest için sınırsız ağaç derinliği (depth=None) ve minimum 2 gözlemlilik dal bölmesinin, Lojistik Regresyon için ise C=1 düzenleme katsayısının seçildiği görülmektedir. Bu parametreler GridSearchCV'nin tabakalı 5-katlı çapraz doğrulama ve F1 skor ölçütüyle yürüttüğü sistematik ızgara aramasının sonucudur ve her katta her iki sınıfın orantılı temsili güvence altına almaktadır.


LOO-CV Model Performansı

LOO-CV değerlendirme sonuçları Tablo 4 ve Şekil 4'te sunulmaktadır.

Tablo 4. LOO-CV Model Performans Metrikleri


Model	Doğruluk	Kesinlik	Duyarlılık	F1
Gradient Boosting	0,971	1,000	0,944	0,971
Lojistik Regresyon	0,971	0,947	1,000	0,973
Rassal Orman	0,971	0,947	1,000	0,973

Tablo 4'e göre Random Forest ve Lojistik Regresyon, LOO-CV değerlendirmesinde eşit F1 skoru (0,973) elde etmiştir. Gradient Boosting ise F1 = 0,971 ile çok yakın bir performans sergilemiştir. Üç modelin birbirine yakın LOO-F1 üretmesi, mevcut dört değişkenin yüksek emisyon rejimine geçişi güvenilir biçimde ayırt etmeye yetecek düzeyde bilgi içerdiğini ortaya koymaktadır. Şekil 4'te dört farklı performans metriği (doğruluk, kesinlik, duyarlılık, F1) açısından üç modelin karşılaştırmalı görünümü sunulmaktadır.



Şekil 4. Model Performans Metriklerinin Karşılaştırması


Gradient Boosting modelinin kesinlik değerinin 1,000 olması özellikle dikkat çekicidir. Bu bulgu modelin yüksek emisyon sınıfı olarak etiketlediği gözlemlerde yanlış pozitif üretmediğini, yüksek emisyon rejiminin tespitinde son derece güvenilir bir ayırt edici yapı sergilediğini göstermektedir. İklim politikası bağlamında bu özellik kritik bir pratik değer taşımaktadır: politika yapımcıların gereksiz alarm tetikleyen değil, yüksek emisyon rejimini isabetle tespit eden bir araçtan yararlandığını ifade etmektedir. LOO-CV sınıflandırma sonuçlarının yıl bazlı görünümü Şekil 5'te sunulmaktadır. Hatalı sınıflandırılan gözlemlerin medyan eşiğine yakın geçiş dönemindeki yıllara (2006-2008 aralığı) karşılık geldiği görülmektedir. Bu durum metodolojik açıdan beklenen bir örüntüyü yansıtmaktadır. Modelin eşik değer yakınındaki belirsiz gözlemleri hatalı sınıflandırdığını, eşikten uzak gözlemleri ise güvenle doğru etiketlediğini ortaya koymaktadır.



Şekil 5. LOO-CV Sınıflandırma Sonuçları

Konfüzyon Matrisi


Gradient Boosting modelinin LOO-CV konfüzyon matrisi Şekil 6'da sunulmaktadır. 35 gözlemin 34'ü doğru sınıflandırılmış; yalnızca 1 gözlem yanlış sınıflandırılmıştır. Düşük emisyon sınıfının 17 gözleminin 16'sı doğru etiketlenmiş, yüksek emisyon sınıfının 18 gözleminin tamamı ise doğru sınıflandırılmıştır. Yalnızca 1 gözlem yanlış etiketlenmiştir. Bu sonuç, medyan eşikliği oluşturulan dengeli sınıf yapısının model kararlılığını artırdığını doğrulamaktadır.



Şekil 6. Konfüzyon Matrisi

Değişken Önem Analizi

Şekil 7 incelendiğinde, Türkiye'nin 1990-2024 dönemi sera gazı emisyonlarını etkileyen faktörlerin üç farklı yöntemle analiz edilen değişken önem hiyerarşisi görülmektedir. Gini Safsızlık Azaltması, Permütasyon Önemi ve SHAP değerlerine dayalı olarak yapılan analizlerin tamamında, GSYİH değişkeninin emisyonlar üzerindeki en baskın belirleyici olduğu tespit edilmiştir. Özellikle Permütasyon analizinde GSYİH'nin 0,4925'lik skorla en yüksek paya sahip olması, ekonomik büyüklüğün Türkiye'deki emisyon hacmini şekillendiren temel itici güç olduğunu doğrulamaktadır.




Şekil 7. Değişken Önem Düzeyleri

Enerji karması açısından bakıldığında, Yenilenebilir Enerji kullanım payının hem Gini hem de SHAP analizlerinde ikinci sırada yer aldığı ve Fosil Yakıt kullanımına oranla emisyon varyansını açıklamada daha kritik bir rol oynadığı görülmektedir. SHAP değerlerinin sunduğu marjinal katkı hiyerarşisinde Yenilenebilir Enerji (0,3012), Fosil Yakıt (0,1648) değişkenini yaklaşık iki kat geride bırakarak, emisyonların tahminlenmesinde temiz enerjiye geçişin stratejik bir öneme sahip olduğunu kanıtlamaktadır. Öte yandan, Dış Ticaret Açıklığı değişkeni her üç yöntemde de en düşük önem skoruna sahip olup, Türkiye özelinde ticari serbestleşmenin emisyonlar üzerindeki etkisinin, ekonomik üretim hacmi ve enerji kaynak yapısı gibi içsel dinamiklerin gerisinde kaldığı

anlaşılmaktadır. Sonuçlar, emisyon kontrol stratejilerinde ekonomik büyüme ile enerji dönüşümü arasındaki ilişkinin merkezi bir konumda olduğunu yöntemsel bir tutarlılıkla ortaya koymaktadır.

SHAP Analizi

Sera gazı emisyon seviyelerini (Sınıf 0: Düşük, Sınıf 1: Yüksek) tahmin etmek amacıyla oluşturulan Rassel Orman (Random Forest) modeline ait SHAP özet grafiği (summary plot) Şekil 8’de sunulmaktadır. Bu şekil, bağımsız değişkenlerin model çıktıları üzerindeki etkisinin hem yönünü hem de büyüklüğünü örneklem bazında detaylandırarak modelin karar mekanizmasını açıklamaktadır.



Şekil 8. SHAP Analizi


Şekil 8 genel olarak incelendiğinde, emisyon sınıfını belirleyen en güçlü ayırt edici faktörün GSYİH (USD) olduğu görülmektedir. Sınıf 1 (Yüksek Emisyon) için GSYİH değişkenine ait yüksek değerlerin (kırmızı noktalar), pozitif SHAP değerleri bölgesinde kümelenmesi, ekonomik büyümeyle artışın yüksek emisyon sınıfına dahil olma olasılığını doğrudan ve şiddetli bir şekilde artırdığını göstermektedir. Buna karşılık, düşük GSYİH değerlerinin (mavi noktalar) negatif etki yaratarak emisyonu düşük sınıfa ittiği gözlenmektedir.

Enerji kaynakları açısından bakıldığında, Yenilenebilir Enerji (%) kullanımının yüksek emisyon sınıfı üzerinde baskılayıcı bir etkisi olduğu saptanmıştır. Yenilenebilir enerji oranındaki artışın (kırmızı noktalar), Sınıf 1 çıktısı için negatif SHAP değerlerine sahip olması, yeşil enerjiye geçişin yüksek emisyon grubunda yer alma riskini azalttığını kanıtlamaktadır. Aksine, Fosil Yakıt (%) kullanımındaki artışın emisyonları yükseltici bir eğilim sergilediği, ancak bu etkinin GSYİH kadar geniş bir etki alanına (SHAP dağılım genişliği) sahip olmadığı saptanmıştır. Dış Ticaret Açıklığı değişkeni ise SHAP ekseninin sıfır noktası etrafında daha dar bir dağılım sergileyerek, Türkiye'nin emisyon sınıflandırması üzerinde diğer değişkenlere kıyasla çok daha sınırlı ve belirsiz bir marjinal katkı sağladığını ortaya koymaktadır. Özetle analiz, Türkiye’de yüksek emisyonun temel sorumlusunun ekonomik büyüme hacmi olduğunu, yenilenebilir enerjinin ise bu olumsuz etkiyi kırmada en stratejik araç olarak konumlandığını doğrulamaktadır.

Nedensel Orman Analizi

SHAP ve değişken önem analizleri değişkenler arasındaki istatistiksel ilişkilerin gücünü ve yönünü ortaya koymaktadır. Ancak bu yöntemler nedensel çıkarım için tasarlanmamıştır. Bir değişkenin model çıktısına olan marjinal katkısını ölçmek, o değişkende gerçekleşecek bir politika müdahalesinin emisyon üzerindeki nedensel etkisini tahmin etmekten farklıdır. Bu ayrımı açıkça ele almak amacıyla çalışmaya Nedensel Orman (Causal Forest) analizi eklenmiştir. Analize ilişkin

ortalama nedensel etki değerleri (Average Treatment Effect - ATE) tüm örneklem için hesaplanmıştır. ATE sonuçları Şekil 9'da gösterilmektedir.



Şekil 9. Değişkenlerin Sera Gazı Üzerindeki Ortalama Nedensel Etkisi (ATE)

ATE bulguları (Şekil 9) incelendiğinde, yenilenebilir enerji payındaki artışın sera gazı emisyonunu ortalama -47,501 Mt azalttığı görülmektedir. Bu etki, %95 güven aralığının sıfırı içermemesi nedeniyle istatistiksel olarak anlamlıdır. GSYİH değişkenindeki artış ise emisyonu ortalama 46,507 Mt artırmaktadır. Bu bulgu, ÇKE hipotezinin Türkiye örneğinde dönüm noktasının henüz aşılmadığına dair SHAP bulgusunu, belirli varsayımlar altında, nedensel düzlemde de destekler niteliktedir. Önceki analizlerde düşük öneme sahip görünen dış ticaret açıklığının emisyon üzerindeki artırıcı etkisi (ATE: +23,623 Mt) nedensel modelde istatistiksel olarak anlamlı çıkmış, kirlilik sığınağı mekanizmasının Türkiye'de nedensel bir iz bıraktığına işaret etmiştir.

Fosil yakıt payının emisyon üzerindeki etkisi ise -31,607 Mt olarak tahmin edilmiş olmakla birlikte, güven aralığının sıfırı içermesi nedeniyle bu etki istatistiksel olarak anlamsızdır. Bu durum, fosil yakıt kullanımının emisyon rejimini belirlemede güçlü bir korelasyon sergilemesine rağmen, nedensel bir müdahale değişkeni olarak etkisinin bu örneklem büyüklüğünde yüksek belirsizlik (geniş güven aralığı) taşıdığını göstermektedir. Bu bulgu, n=35 gibi kısıtlı bir örneklemde Nedensel Orman algoritmasının bazı değişkenlerde güvenilir tahminler üretmekte zorlanabileceğini, yöntemin tam etkinliği için daha geniş veri setlerine ihtiyaç duyulduğunu ortaya koymaktadır.

Bu noktada SHAP ve Nedensel Orman bulgularının birbirini tamamladığı, ancak farklı soruları yanıtladığı vurgulanmalıdır. SHAP analizi 'hangi değişken emisyon tahmininde en güçlü ayrıştırıcıdır?' sorusuna yanıt verirken, Nedensel Orman 'hangi değişkende gerçekleştirilecek bir müdahale emisyonu en güvenilir biçimde değiştirir?' sorusuna odaklanmaktadır. Bu çerçevede, istatistiksel anlamlılık ve etki büyüklüğü bakımından yenilenebilir enerji payı (-47,501 Mt) emisyon azaltımı için en etkili politika aracı olarak öne çıkmaktadır. İki yöntemin sunduğu hiyerarşik farklılıklar bir çelişki değil, aksine politika yapıcılar için metodolojik bir derinlik sunmaktadır: Ekonomik büyüme ve mevcut enerji yapısı emisyonun temel belirleyicisi olsa da nedensel analiz, gözlemlenebilir karıştırıcıların kontrol edildiği koşullu bağımsızlık varsayımı altında, yenilenebilir enerji kapasitesinin artırılmasının daha öngörülebilir bir emisyon azalışıyla ilişkili olduğuna işaret etmektedir.

Sonuçlar

Bu çalışma, Türkiye'nin 1990-2024 dönemine ait yıllık verileriyle sera gazı emisyonu düzeyinin belirleyicilerini makine öğrenmesi tabanlı sınıflandırma yöntemiyle incelemiştir. Sera gazı serisinin medyanı olan 395,9 Mt CO₂ eşdeğeri eşiği temelinde oluşturulan ikili sınıflandırma çerçevesinde Gradient Boosting, Random Forest ve Lojistik Regresyon algoritmaları karşılaştırmalı

olarak değerlendirilmiş; modellerin performansı LOO-CV ile ölçülmüş, yorumlanabilirlik SHAP analizi ve Nedensel Orman yöntemiyle derinleştirilmiştir.

LOO-CV sonuçlarına göre Random Forest ve Lojistik Regresyon $F1 = 0,973$, Gradient Boosting ise $F1 = 0,971$ performansı sergilemiştir. Gradient Boosting ve Lojistik Regresyon modellerinin kesinlik değerinin 1,000 düzeyine ulaşması, yüksek emisyon rejiminin tespitinde sıfır yanlış pozitif üretildiğini ve modelin politika uygulamaları için güvenilir bir ayırt edici yapı sergilediğini ortaya koymaktadır. SHAP analizi, emisyon rejimini belirleyen birincil değişken olarak GSYİH'ı belirlemiştir. Diğer belirleyiciler sırasıyla yenilenebilir enerji payı, fosil yakıt payını ve dış ticaret açıklığı olmuştur. Nedensel Orman analizi ise istatistiksel anlamlılık bakımından yenilenebilir enerji payını (ATE: -47,501 Mt) ve GSYİH'yı (ATE: 46,507 Mt) öne çıkararak SHAP bulgularını nedensel bir perspektiften tamamlamıştır. Bulgular ayrıca Türkiye'nin 2007 yılından itibaren yüksek emisyon rejimine kalıcı biçimde geçtiğini ortaya koymaktadır.

Çalışma yazına dört temel katkı sunmaktadır. Birincisi, sera gazı emisyon değişkenini regresyon problemini yerine sınıflandırma problemi olarak yeniden kurgulaması, bulguların iklim politikası süreçlerine doğrudan aktarımını mümkün kılmaktadır. İkincisi, küçük örneklem koşullarında LOO-CV ile güvenilir model değerlendirmesi sağlanmıştır. Böylece veri sızıntısı ve aşırı öğrenme riskleri yapısal olarak bertaraf edilmiştir. Üçüncüsü, SHAP çerçevesinin entegrasyonu topluluk algoritmalarını yorumlanabilir bir analiz aracına dönüştürmektedir. Dördüncüsü, Nedensel Orman analizinin eklenmesiyle korelasyon ve nedensellik arasındaki metodolojik ayrım açıkça ortaya konulmuş ve politika yapıcılara yalnızca "ne ilişkili?" değil, "ne müdahale edilebilir?" sorusuna yanıt sunulmuştur.

Araştırma sorularına ilişkin sonuçlar değerlendirildiğinde; birinci soruya ilişkin olarak, LOO-CV sonuçları makine öğrenmesi algoritmalarının Türkiye'nin sera gazı emisyon rejimini yüksek doğrulukla sınıflandırabildiğini ortaya koymaktadır. İkinci soruya ilişkin olarak, SHAP analizi GSYİH'yı birincil belirleyici olarak tespit etmiştir ve sırasıyla yenilenebilir enerji payı, fosil yakıt payı ve dış ticaret açıklığı diğer belirleyici değişkenler olmuşlardır. Üçüncü soruya ilişkin olarak, Nedensel Orman analizi yenilenebilir enerji payı ve GSYİH'nın emisyon üzerindeki nedensel etkisini istatistiksel olarak anlamlı bulurken fosil yakıt payının etkisi küçük örneklem kısıtı nedeniyle anlamlılığa ulaşamamıştır.

Tartışma

Bu çalışmanın bulguları, Türkiye'de sera gazı emisyonu belirleyicilerine ilişkin mevcut yazınla büyük ölçüde örtüşmekle birlikte birkaç önemli noktada ayrılmakta ve yazına özgün katkılar sunmaktadır.

Sınıflandırma modellerinin performansı değerlendirildiğinde, Random Forest ve Lojistik Regresyon algoritmalarının LOO-CV $F1 = 0,973$ ile güçlü ve kararlı bir tahmin gücü sergilediği görülmektedir. Gradient Boosting da $F1 = 0,971$ ile çok yakın bir performans sergilemiştir. Rufaioğlu vd. (2025), Türkiye'nin sera gazı verilerinde Gradient Boosting'in $R^2 = 0,995$ ile en yüksek doğruluğa ulaştığını göstermiştir. Metodolojik düzeyde, bu çalışmada toplu algoritmaların, SHAP analizinin ve nedensel orman çıkarımının entegre kullanımı, Sert (2026) tarafından geçerliliği kanıtlanan yaklaşıma paraleldir. Söz konusu yaklaşımda, aynı metodolojik üçlünün, emisyon modellemesinden farklı bir sosyoekonomik bağlamda nedensel temelli ve politika düzeyinde uygulanabilir içgörüler ürettiği gösterilmiştir. Regresyon ve sınıflandırma gibi farklı problem çerçevelerinde elde edilen bu paralel bulgular, topluluk öğrenmesi algoritmalarının Türkiye'nin emisyon dinamiklerini modellemedeki üstünlüğünü tutarlı biçimde teyit etmektedir.

SHAP analizinde GSYİH'nın birincil belirleyici faktör olarak ortaya çıkması, EKC hipotezinin Türkiye için koşullu geçerliliğini desteklemekte ve Katırcıoğlu (2014), Pata (2018) ile Gövdeli (2019) tarafından ortaya konulan uzun vadeli bulgularla uyumludur. Bu araştırmacılar,

yapısal kırılmalar bağlamında Türkiye'nin henüz gelir dönüm noktasını geçmediğini teyit etmişlerdir. Bu bulgu, Açıkgöz ve Öncel (2024) tarafından N-11 düzeyinde de doğrulanmaktadır. Bu araştırmacılar, ekonomik büyümenin çevresel bozulma üzerindeki etkisinin N-11 ekonomileri arasında önemli ölçüde farklılık gösterdiğini ortaya koymuşlardır. Bu bulgu, Türkiye'nin yüksek emisyon rejimi olarak sınıflandırılması uyumludur. Yenilenebilir enerji payının ikinci sırada anlamlı bir emisyon azaltıcı etki sergilemesi, Pata'nın (2018) bulgularını ve Beken vd.'nin (2019) yenilenebilir enerji kapasitesinin artmasıyla Türkiye'nin daha düşük emisyon profiline sahip ülke kümelerine yaklaştığını gösteren bulgusunu desteklemektedir.

GSYİH'nın çift yönlü SHAP dağılımı ÇKE hipotezi açısından değerli bir bulgu sunmaktadır. Düşük GSYİH değerlerinin yüksek emisyon olasılığını artırması, Türkiye'nin henüz dönüm noktasına ulaşmış olmadığını tartışan yazınla (Katırcıoğlu, 2014; Pata, 2018) örtüşmektedir. Han & Lin (2025), ÇKE hipotezinin yorumlanabilir makine öğrenmesiyle ele alındığında ülkeye özgü eşik koşullarının ortaya çıktığını göstermiştir. Bu bulgu GSYİH'nın doğrusal olmayan SHAP dağılımını teorik düzlemde desteklemektedir.

Ticaret açıklığının SHAP analizinde son sırada yer alması, kirlilik sığınağı hipotezini güçlü bir şekilde destekleyen Cole (2004)'un bulgularıyla kısmen çelişmektedir. Bununla birlikte, Nedensel Orman analizi, bu değişkenin ATE değerinin 23,623 Mt olduğunu ve güven aralığının sıfırı içermediğini ortaya koymaktadır. Bu bulgu, ticaretin açıklığının öngörü gücü açısından sınırlı olmasına rağmen, nedensel düzeyde emisyonlar üzerinde önemli bir artış etkisi olduğunu göstermektedir. Bu durum, kirlilik sığınağı mekanizmasının Türkiye örneğinde birincil bir kanal olmaktan ziyade ikincil ve koşullu bir kanal olarak işlediğini düşündürmektedir. Bu bulgu, ticaretle bağlantılı değişkenler ile CO2 emisyonları arasındaki ilişkinin kurumsal ve teknolojik faktörler tarafından aracılık edildiğini gösteren Yılmaz (2020) ile genel olarak tutarlıdır. Bu durum, kirlilik sığınağı mekanizmasının tek tip bir kanal olarak değil, daha çok ülkeye özgü yapısal özellikler tarafından şekillendirilen koşullu bir kanal olarak işlediğini göstermektedir.

Nedensel Orman analizi, SHAP bulgularını tamamlayan ancak farklı bir perspektiften değerlendiren sonuçlar üretmiştir. SHAP'ta üçüncü sıraya yerleşen fosil yakıt payının ATE değeri istatistiksel olarak anlamlı bulunmamıştır (ATE: -31,607 Mt, Güven Aralığı: [-67, +13]). Buna karşın yenilenebilir enerji payı (ATE: -47,501 Mt, Güven Aralığı: [-63, -32]) ve GSYİH (ATE: +46,507 Mt, Güven Aralığı: [+30, +63]) nedensel düzlemde istatistiksel anlamlılığa ulaşmıştır. Bu sonuç, Ayvaz Güven (2026) tarafından da doğrulanmaktadır. Yazar, G20 ülkeleri için panel tahminlerini kullanarak yenilenebilir enerji tüketiminin karbon ekolojik ayak izini önemli ölçüde azalttığını ortaya koymuştur. Türkiye için yapılan nedensel orman tahmini ile G20 için yapılan panel tabanlı tahminin birbiriyle uyumlu olması, bu bulgunun dış geçerliliğini güçlendirmektedir. Dış ticaret açıklığının da emisyonlar üzerinde pozitif yönlü ve anlamlı bir nedensel etkiye sahip olduğu görülmektedir (ATE: +23,623 Mt). Bu ayrışma, SHAP ve Nedensel Orman yöntemlerinin farklı soruları yanıtladığını açıkça ortaya koymaktadır: SHAP "hangi değişken emisyon sınıfını en güçlü biçimde ayrıştırıyor?" sorusunu yanıtlarken, Nedensel Orman "hangi değişkende gerçekleştirilecek bir müdahale emisyonu en güvenilir biçimde azaltır?" sorusunu yanıtlamaktadır. İki yöntemin birlikte kullanılması tek bir yönetime kıyasla çok daha zengin ve politika açısından işlevsel bulgular üretmektedir. Fosil yakıt payının istatistiksel anlamlılığa ulaşamaması ise büyük ölçüde $n = 35$ gibi küçük bir örneklemede Nedensel Orman algoritmasının "treatment" değişkenindeki dar varyasyonu (fosil yakıt payı %82-91 aralığında seyrediyor) yeterince işleyememesinden kaynaklanmaktadır.

Metodolojik düzlemde LOO-CV $F1 = 0,973$ ile ulaşılan performans, Bakır vd.'nin (2022) ve Hasan vd.'nin (2025) küçük veri setlerinde topluluk modellerinin daha kararlı sonuçlar ürettiğini gösteren bulgularıyla karşılaştırılabilir niteliktedir. Kesinlik değerinin 1,000 olması, politika uygulamaları açısından özellikle değerlidir. Bu durum, gereksiz alarm üretmeyen, yüksek emisyon rejimini isabetle tespit eden bir araç sunmaktadır. Leerbeck vd.'nin (2020) veri kalitesinin artmasıyla

alanın önemli potansiyel barındırdığına ilişkin vurgusu ise $n = 35$ gözlemlik bu çalışmanın kısıtı bağlamında gelecek araştırmalar için somut bir yol gösterici olmaya devam etmektedir.

Politika Önerileri

Çalışmanın bulguları, Türkiye'nin iklim politikası tasarımı açısından birbiriyle bağlantılı somut önermeler doğurmaktadır.

Yenilenebilir enerji kapasitesinin önceliklendirilmesi. Nedensel Orman analizi, yenilenebilir enerji payındaki artışın istatistiksel olarak anlamlı biçimde sera gazı emisyonunu azalttığını ortaya koymuştur (ATE: -47,501 Mt). Bu bulgu, yenilenebilir enerji kapasitesinin genişletilmesinin yalnızca enerji arz güvenliği değil, doğrudan iklim politikası hedefleri bakımından da birincil bir politika kaldırıcı niteliği taşıyabileceğine işaret etmektedir. Güneş ve rüzgar enerjisi yatırımlarının önündeki bürokratik ve finansal engellerin azaltılması, enerji depolama kapasitesinin geliştirilmesi ve dağıtık üretim modellerinin teşvik edilmesi bu doğrultuda değerlendirilebilecek araçlar olarak sunulabilir.

Fosil yakıt bağımlılığının azaltılması. SHAP analizi fosil yakıt payını emisyon rejimini belirleyen üçüncü değişken olarak tespit etmiştir. Ancak GSYİH ve yenilenebilir enerji payından sonra gelmesi bu değişkenin politika açısından önemini azaltmamaktadır. Her ne kadar Nedensel Orman analizinde bu değişkenin ATE değeri istatistiksel anlamlılığa ulaşamamış olsa da bu sonuç etkisizliği değil, örneklem büyüklüğü kısıtından kaynaklanan ölçüm gücünü yansıtmaktadır. Kömür santrallerinin aşamalı kapatılması, doğalgaz bağımlılığının azaltılması ve enerji verimliliği yatırımlarının önündeki engellerin kaldırılması yapısal dönüşümün önceliklendirilmesi gereken bileşenleri olarak değerlendirilebilir.

Büyüme-emisyon ilişkisinin yönetimi. GSYİH'nın hem SHAP analizindeki doğrusal olmayan dağılımı hem de Nedensel Orman'daki anlamlı artırıcı etkisi (ATE: 46,507 Mt), ekonomik büyüme stratejisinin iklim politikasıyla entegre biçimde tasarlanması gerektiğine işaret etmektedir. Özellikle ekonomik daralma dönemlerinde çevre politikası bütçelerinin baskı altına girdiği ve enerji yoğun sektörlerin görece ağırlık kazandığı göz önünde bulundurulduğunda, karbon fiyatlandırması ve yeşil vergi reformu gibi piyasa tabanlı araçların ekonomik döngüden bağımsız işleyen istikrarlı bir politika çerçevesine oturtulması büyük önem taşımaktadır.

Çalışmanın Sınırlılıkları ve Gelecek Araştırma Önerileri

Bu çalışma bazı sınırlılıkları bünyesinde barındırmaktadır.

İlk olarak analiz, $n = 35$ yıllık gözlemden oluşan görece küçük bir örneklem üzerine inşa edilmiştir. LOO-CV bu kısıtı metodolojik olarak minimize etmekle birlikte, daha büyük örneklemelerde hem sınıflandırma hem de nedensel çıkarım tahminlerinin güvenilirliği doğal olarak artacaktır. Bu sınırlılık özellikle Nedensel Orman analizinde belirgin biçimde hissedilmektedir: fosil yakıt payının güven aralığının sıfırı içermesi, büyük ölçüde küçük örneklem ve “treatment” değişkenindeki dar varyasyondan kaynaklanmaktadır. Algoritmanın anlamlı etki farklılıklarını yakalayabilmesi için yüzü aşkın gözlem gerekmektedir (Wager & Athey, 2018).

İkinci sınırlılık, sınıflandırma eşiği olarak tek bir istatistiksel referans noktasının (395,9 Mt-medyan) benimsenmesidir. Alternatif eşik değerleri altında model davranışının nasıl farklılaştığı bu çalışma kapsamında incelenmemiştir. Medyan eşiği yerine farklı eşik değerleri kullanılarak sağlamlık testi yapılması gelecek çalışmalara önerilebilir.

Üçüncüsü, çalışma ulusal düzey toplulaştırılmış verilerle çalışmaktadır ve sera gazı emisyon dinamiklerinin sektörel kırılımını (enerji, ulaştırma, sanayi, tarım ve atık...vb) ayrı ayrı ele almamaktadır. Sektörel düzeyde makine öğrenmesi tabanlı analizler hem sınıflandırma modellerinin hem de nedensel çıkarım yöntemlerinin etkinliğini önemli ölçüde artırabilecektir.

Gelecek arařtırmalar için birkaç yön öne çıkmaktadır. Çok sınıflı sınıflandırma tasarımının benimsenmesi, emisyon rejimlerinin daha ince bir ayrımla tanımlanmasına olanak tanıyabilir. Çeyreklik verilerin kullanılması, örneklem büyüklüğünü dört katına çıkararak hem sınıflandırma hem de Nedensel Orman analizlerinin güvenilirliğini artırabilecektir. Uzun kısa süreli bellek ağıları (LSTM) veya zamansal evriřimli ağılar (TCN) gibi derin öğrenme mimarilerinin, daha uzun zaman serisi verileri mevcut olduėunda uygulanması karşılařtırmalı bir metodolojik perspektif sunacaktır. Ancak bu mimarilerin etkin çalışması için genellikle yüzü aşkın gözlem gerekmektedir (Goodfellow vd., 2016). Son olarak Türkiye ile benzer gelişme düzeyindeki ekonomileri kapsayan karşılařtırmalı panel analizleri, enerji dönüşümünün emisyon rejimine etkisinin ülkeler arasında nasıl farklılařtığını ortaya koyabilecektir.

References

- Abdulrazagova, K., Kır, B., & Kocabıyık Çaşkurlu, S. (2025). From traditional methods to digitalization: The transformation of the ready-to-wear industry. *Turkish Studies*, 20(Ö1), 1–16. <https://doi.org/10.7827/TurkishStudies.80296>
- Açıkgöz, F., & Öncel, A. (2024). N-11 ülkelerinde ekonomik büyüme, fosil yakıt tüketimi ve küreselleşmenin çevresel bozulma üzerindeki etkisinin ülke bazlı araştırılması. *Turkish Studies - Economy*, 19(1), 1–22. <https://doi.org/10.7827/TurkishStudies.71256>
- Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: A survey on explainable artificial intelligence (XAI). *IEEE Access*, 6, 52138–52160. <https://doi.org/10.1109/ACCESS.2018.2870052>
- Ağbulut, Ü. (2022). Forecasting of transportation-related energy demand and CO2 emissions in Turkey with different machine learning algorithms. *Sustainable Production and Consumption*, 29, 141–157. <https://doi.org/10.1016/j.spc.2021.10.001>
- Ahmed, M. A. U., & Hamod, M. (2026). The effectiveness of using artificial intelligence models and active learning to assess hadith reading skills: Innovation and development [Hadis okuma becerisinin değerlendirilmesinde yapay zekâ modellerinin ve aktif öğrenmenin kullanım etkililiği: İnovasyon ve geliştirme]. *Turkish Studies - Comparative Religious Studies*, 21(1), 1–48. <https://doi.org/10.7827/TurkishStudies.89106>
- Akdağ, F., & Parlak Biçer, Z. Ö. (2025). Ekolojik mimarlık perspektifinden sıkıştırılmış toprak: Uygulamalar üzerinden bir inceleme. *Turkish Studies*, 20(3), 1239–1274. <https://doi.org/10.7827/TurkishStudies.86554>
- Akyıldız, S. G., & Akyıldız, Y. (2020). *Westworld* dizisinde makine öğrenmesi: Cinsiyet eşitsizliğini yeniden üreten yapay zekâ yaratımları. *Turkish Studies*, 15(2), 999–1010. <https://doi.org/10.29228/TurkishStudies.41975>
- Aldoori, A. J. M., & Benchalel, S. R. (2026). Sünnet-i Nebevî ışığında insan inşası ve sürdürülebilir kalkınmadaki etkisi. *Turkish Studies - Comparative Religious Studies*, 21(2), 2071–2117. <https://doi.org/10.7827/TurkishStudies.90603>
- Altındış, F. (2020). General evaluation on non-emotional investment method “algorithmic trading” and sample of algorithm study. *Turkish Studies*, 15(1), 23–34. <https://doi.org/10.29228/TurkishStudies.37827>
- Altıntaş, F. F. (2021). G7 grubu ülkelerin iklim değişikliği koruma performanslarının CODAS ve EDAS yöntemleri ile incelenmesi. *Turkish Studies*, 16(4), 1181–1201. <https://doi.org/10.7827/TurkishStudies.51022>
- Apergis, N., & Payne, J. E. (2009). CO2 emissions, energy usage, and output in Central America. *Energy Policy*, 37(8), 3282–3286. <https://doi.org/10.1016/j.enpol.2009.03.048>
- Ardaturk, A. S. (2026). An analysis of the sector: Digital interfaces and techniques used in the design offices [Bir sektör analizi: Tasarım ofislerinde kullanılan dijital arayüzler ve teknikler]. *Turkish Studies*, 21(1), 143–197. <https://doi.org/10.7827/TurkishStudies.87841>
- Arduç Kara, E. (2026). Artificial intelligence fatigue, technostress and journalism: A conceptual literature review [Yapay zekâ yorgunluğu, teknostres ve gazetecilik: Kavramsal bir literatür taraması]. *Turkish Studies*, 21(1), 199–235. <https://doi.org/10.7827/TurkishStudies.87954>
- Arğın, E. (2026). Ethics and artificial intelligence: Data privacy and algorithmic transparency in social sciences [Yapay zekâ ve etik: Sosyal bilimlerde veri gizliliği ve algoritmik şeffaflık]. *Turkish Studies*, 21(2), 2111–2155. <https://doi.org/10.7827/TurkishStudies.86847>

- Arıcı, N., & Karacı, A. (2013). Türkçe öğrenimi için web tabanlı zeki öğretim sistemi (TÜRKZÖS) ve değerlendirmesi. *Turkish Studies*, 8(8), 65–87. <https://doi.org/10.7827/TurkishStudies.4878>
- Arlot, S., & Celisse, A. (2010). A survey of cross-validation procedures for model selection. *Statistics Surveys*, 4, 40–79. <https://doi.org/10.1214/09-SS054>
- Aşkun, V. (2024). ChatGPT gibi üretken yapay zekalar ile insan kaynakları yönetimi etkileşimi: Daha fazla çalışma için görüşler ve yollar. *Turkish Studies - Economics, Finance, Politics*, 19(2), 679–699. <https://doi.org/10.7827/TurkishStudies.75863>
- Athey, S., & Imbens, G. (2016). Recursive partitioning for heterogeneous causal effects. *Proceedings of the National Academy of Sciences*, 113(27), 7353–7360. <https://doi.org/10.1073/pnas.1510489113>
- Ayaz, İ. (2024). Forecasting CO₂ emissions with machine learning methods: Türkiye example and future trends. *Naturengs*, 5(2), 82–87. <https://doi.org/10.46572/naturengs.1595329>
- Aydın, L., & Arı, İ. (2019). Challenges on processes for the implementation of Paris Agreement: Major fossil fuel producers case. *Turkish Studies - Economics, Finance, Politics*, 14(4), 1173–1186. <https://doi.org/10.29228/TurkishStudies.32703>
- Aytekin, H., & Ateş, E. (2019). Küreselleşme ekseninde yeni kavramlar. *Turkish Studies - Language and Literature*, 14(4), 1789–1804. <https://doi.org/10.29228/TurkishStudies.39847>
- Aytepe Serinsu, B. (2022). Sürdürülebilir yaşayan seramikler. *Turkish Studies*, 17(5), 971–983. <https://doi.org/10.7827/TurkishStudies.63614>
- Ayvaz Güven, E. T. (2026). The relationship between renewable energy and carbon ecological footprint: The example of G20 countries [Yenilenebilir enerji ve ekolojik ayak izi arasındaki ilişki: G20 ülkeleri örneği]. *Turkish Studies - Economics, Finance, Politics*, 21(2), 2165–2205. <https://doi.org/10.7827/TurkishStudies.88813>
- Bahadır, M. (2012). Kovada Gölü seviye değişimlerinin istatistiksel analizi. *Turkish Studies*, 7(3), 441–452. <https://doi.org/10.7827/TurkishStudies.2465>
- Bakır, H., Ağbulut, Ü., Gürel, A. E., Yıldız, G., Güvenç, U., & Sağlam, Ş. (2022). Forecasting of future greenhouse gas emission trajectory for India using energy and economic indexes with various machine learning algorithms. *Journal of Cleaner Production*, 360, Article 131946. <https://doi.org/10.1016/j.jclepro.2022.131946>
- Baran, Z. (2022). Geleneksel yemeklerde dijital gastronomi vizyonu. *Turkish Studies*, 17(4), 685–703. <https://doi.org/10.7827/TurkishStudies.62028>
- Başar, F. (2025). The relationship between ChatGPT use, academic engagement, and life satisfaction: An empirical study in a faculty of tourism. *Turkish Studies*, 20(4), 2131–2144. <https://doi.org/10.7827/TurkishStudies.86796>
- Bayat Arslan, S., & Cuma, A. (2026). Local language and cultural gaps in AI-generated literary production: Turkish folk and German folk literature examples [Yapay zekâ edebî üretiminde yerel dil ve kültür boşlukları: Türk halk ve Alman halk edebiyatı örnekleri]. *Turkish Studies - Language and Literature*, 21(2), 2479–2558. <https://doi.org/10.7827/TurkishStudies.89780>
- Beken, M., Hangun, B., & Eyecioglu, O. (2019). Classification of Turkey among European countries by years in terms of energy efficiency, total renewable energy, energy consumption, greenhouse gas emission and energy import dependency by using machine learning. In *2019 8th International Conference on Renewable Energy Research and Applications (ICRERA)* (pp. 951–956). IEEE.

- Bekil, N. (2018). Transhumanism: Immortality & singularity in *Do androids dream of electric sheep?* & *The transhumanist wager*. *Turkish Studies - Social Sciences*, 13(18), 251–262. <https://doi.org/10.7827/TurkishStudies.13790>
- Bhatt, H., Davawala, M., Joshi, T., Shah, M., & Unnarkat, A. (2023). Forecasting and mitigation of global environmental carbon dioxide emission using machine learning techniques. *Cleaner Chemical Engineering*, 5, Article 100095. <https://doi.org/10.1016/j.clce.2023.100095>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- Büyükboyacı, Ş., & Yozcu, Ö. (2026). The codes of mental transformation in education: A thematic analysis of graduate social studies students' perspectives on artificial intelligence [Eğitimde zihinsel dönüşümün kodları: Lisansüstü sosyal bilgiler öğrencilerinin yapay zekâya ilişkin görüşlerinin tematik analizi]. *Turkish Studies*, 21(1), 623–665. <https://doi.org/10.7827/TurkishStudies.87753>
- Chernozhukov, V., Chetverikov, D., Demirer, M., Duflo, E., Hansen, C., Newey, W., & Robins, J. (2018). Double/debiased machine learning for treatment and structural parameters. *The Econometrics Journal*, 21(1), C1–C68. <https://doi.org/10.1111/ectj.12097>
- Civelek, S. (2025). From tradition to dataset: Digital archiving of traditional artistic heritage and the ethical and epistemological consequences of its use as training data for artificial intelligence. *AIS3, Artificial Intelligence Studies in Society, Science, and Systems*, 1(1), 26–43.
- Cole, M. A. (2004). Trade, the pollution haven hypothesis and the environmental Kuznets curve: Examining the linkages. *Ecological Economics*, 48(1), 71–81. <https://doi.org/10.1016/j.ecolecon.2003.09.007>
- Coşkun, O. (2025). *Les Indes noires*'ın Türkçe çevirileri: İnsan ve yapay zekâ çevirisinin karşılaştırılması. *Turkish Studies - Language and Literature*, 20(Ö1), 291–320. <https://doi.org/10.7827/TurkishStudies.88179>
- Çakmak, B. (2025). Duygusal tipografi: Yazı tiplerinin semantik potansiyeli ve görsel iletişimde yapay zekâ (DALL-E) yorumlaması. *Turkish Studies*, 20(Ö1), 191–214. <https://doi.org/10.7827/TurkishStudies.82281>
- Çark, Ö. (2020). İşletmelerin dijital dönüşüm sürecinde “nesnelerin interneti” teknolojisinin etkisi. *Turkish Studies - Economics, Finance, Politics*, 15(3), 1247–1266. <https://doi.org/10.47644/TurkishStudies.41888>
- Çelik, R., Çiçeklioğlu, H., & Yazıcı, A. M. (2025). Geleceği beslemek: Girişim sermayesinin yapay zeka hesaplama girişimleri ve sürdürülebilir yenilik üzerindeki etkisi. *Turkish Studies - Economics, Finance, Politics*, 20(4), 2191–2214. <https://doi.org/10.7827/TurkishStudies.82939>
- Çınarar, G., Yeşilyurt, M. K., Ağbulut, Ü., Yılbaşı, Z., & Kılıç, K. (2024). Application of various machine learning algorithms in view of predicting the CO2 emissions in the transportation sector. *Science and Technology for Energy Transition*, 79, Article 15. <https://doi.org/10.2516/stet/2024014>
- Çora, H., Mikail, E. H., & Çora, A. N. (2026). Algorithmic diplomacy: AI-assisted decision-making models and ethical boundaries in international relations [Algoritmik diplomasi: Yapay zekâ destekli karar alma modelleri ve uluslararası ilişkilerde etik sınırlar]. *Turkish Studies*, 21(1), 801–850. <https://doi.org/10.7827/TurkishStudies.87722>

- Çoşgun, A. (2024). Estimation of Turkey's carbon dioxide emission with machine learning. *International Journal of Computational and Experimental Science and Engineering*, 10(1), 95-101. <https://doi.org/10.22399/ijcesen.302>
- Dalmış, E. (2026). AI performance in translating rich points: A comparative analysis of ChatGPT, DeepSeek and Gemini [Çeviride zengin noktalar üzerinden yapay zekâ performansı: ChatGPT, DeepSeek ve Gemini sistemleri üzerine karşılaştırmalı bir inceleme]. *Turkish Studies - Language and Literature*, 21(1), 681-727. <https://doi.org/10.7827/TurkishStudies.88767>
- Demir, F., & Süslü, N. E. (2022). Doğa-insan ilişkisini anlamak: Ekolojizm ve edebiyattaki izleri. *Turkish Studies - Language and Literature*, 17(1), 187-205. <https://doi.org/10.7827/TurkishStudies.57660>
- Denizci, Ö. M., Kırık, A. M., & Çetinkaya, A. (2018). A learning-based approach to fuzzy logic in framework of philosophy of informatics. *Turkish Studies - Information Technologies & Applied Sciences*, 13(29), 47-59. <https://doi.org/10.7827/TurkishStudies.14730>
- Doğru, A., & Hacımuftuoğlu, E. (2025). Tefsirde yapay zekâ uygulamalarının kullanımı: ChatGPT-4o, Google Gemini Advanced 1.5 Pro ile Microsoft Copilot'un karşılaştırması. *Turkish Studies - Comparative Religious Studies*, 20(4), 1867-1891. <https://doi.org/10.7827/TurkishStudies.87246>
- Doğru, S., & Demirbaş, İ. (2020). Ortaokul öğrencilerinin elektrik ve yenilenebilir enerji kaynakları hakkındaki düşünceleri arasındaki bağlantının incelenmesi. *Turkish Studies - Educational Sciences*, 15(6), 4151-4167. <https://doi.org/10.47423/TurkishStudies.45576>
- Efendioğlu, İ. H. (2023). Yapay zekâ pazarlaması: İnternette yapılan alışverişlerde yapay zekânın satın alma niyetine etkisi. *Turkish Studies - Economics, Finance, Politics*, 18(1), 133-153. <https://doi.org/10.7827/TurkishStudies.66785>
- Ekinci, E. (2025). Yerel yönetimlerde yapay zekâ algısı: Yozgat Belediyesi örneği. *Turkish Studies - Economics, Finance, Politics*, 20(3), 1441-1467. <https://doi.org/10.7827/TurkishStudies.81663>
- Ene Yalçın, S. (2024). Development of a forecasting framework based on advanced machine learning algorithms for greenhouse gas emissions. *Systems*, 12(12), Article 528. <https://doi.org/10.3390/systems12120528>
- Erdem, M. D., & Demiryakan, D. (2025). On language education, linguistic inequality, and linguistic justice. *AIS3, Artificial Intelligence Studies in Society, Science, and Systems*, 1(1), 1-25.
- Erdoğan, M., & Ganiev, J. (2016). Orta Asya ülkelerinde CO2 emisyonu, iktisadi ve finansal gelişme ve fosil yakıt enerji tüketimi ilişkisi. *Turkish Studies*, 11(21), 471-486. <https://doi.org/10.7827/TurkishStudies.11214>
- Ertan, İ. F. (2026). Generative artificial intelligence in digital games [Dijital oyunlarda üretken yapay zekâ]. *Turkish Studies*, 21(1), 1125-1161. <https://doi.org/10.7827/TurkishStudies.88191>
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, 29(5), 1189-1232. <https://doi.org/10.1214/aos/1013203451>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. MIT Press.
- Gökçe, H. U., & Gökçe, K. U. (2020). Binalarda enerji verimliliği için gerekli algılayıcıların özgün olarak geliştirilmesi projesi tekno-ekonomik analizi. *Turkish Studies - Information Technologies and Applied Sciences*, 15(3), 325-344. <https://doi.org/10.47844/TurkishStudies.44680>

- Gövdeli, T. (2019). An empirical analysis of the environmental Kuznets curve under structural breaks: The example of Turkey. *Turkish Studies - Economics, Finance, Politics*, 14(2), 307–318. <https://doi.org/10.29228/TurkishStudies.22904>
- Grossman, G. M., & Krueger, A. B. (1991). *Environmental impacts of a North American free trade agreement* (NBER Working Paper No. 3914). National Bureau of Economic Research. <https://doi.org/10.3386/w3914>
- Gujarati, D. N., & Porter, D. C. (2009). *Basic econometrics* (5th ed.). McGraw-Hill.
- Gunning, D., & Aha, D. (2019). DARPA's explainable artificial intelligence (XAI) program. *AI Magazine*, 40(2), 44–58. <https://doi.org/10.1609/aimag.v40i2.2850>
- Güçlüten, Ç. (2026). The securitization of cross-border migration movements: Digital solutions and their impacts on law enforcement agencies [Sınır ötesi göç hareketlerinin güvenlikleştirilmesi: Kolluk kuvvetlerinin dijital çözümleri ve etkileri]. *Turkish Studies - Economics, Finance, Politics*, 21(2), 2773–2808. <https://doi.org/10.7827/TurkishStudies.88553>
- Günay, M. (2025). The role of the aesthetic value function in evolutionary art generation. *AIS3, Artificial Intelligence Studies in Society, Science, and Systems*, 1(1), 44–67.
- Güzel, K. (2024). Bir distopik bilim kurgu oyunu örneği olarak *Landscape with Weapon*'in mühendislik etiği bağlamında incelenmesi. *Turkish Studies - Language and Literature*, 19(2), 617–638. <https://doi.org/10.7827/TurkishStudies.76479>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). *Multivariate data analysis* (7th ed.). Pearson.
- Halicioğlu, F. (2009). An econometric study of CO2 emissions, energy consumption, income and foreign trade in Turkey. *Energy Policy*, 37(3), 1156–1164. <https://doi.org/10.1016/j.enpol.2008.11.012>
- Han, T. T. T., & Lin, C. Y. (2025). Exploring long-run CO2 emission patterns and the environmental Kuznets curve with machine learning methods. *Innovation and Green Development*, 4(1), Article 100195. <https://doi.org/10.1016/j.igd.2024.100195>
- Hasan, M. S., Tarequzzaman, M., Moznuzzaman, M., & Juel, M. A. A. (2025). Prediction of energy consumption in four sectors using support vector regression optimized with genetic algorithm. *Heliyon*, 11(2), Article e41765. <https://doi.org/10.1016/j.heliyon.2025.e41765>
- He, H., & Garcia, E. A. (2009). Learning from imbalanced data. *IEEE Transactions on Knowledge and Data Engineering*, 21(9), 1263–1284. <https://doi.org/10.1109/TKDE.2008.239>
- Işık, M., & Darı, A. B. (2023). Yapay zeka film afişlerinin göstergebilimsel analizi: *Artificial Intelligence, Frank & Robot, Ex_Machina* örneği. *Turkish Studies*, 18(1), 63–82. <https://doi.org/10.7827/TurkishStudies.64322>
- İçel, G. (2014). Mersin'de meteorolojik ve hidrometeorolojik afetler. *Turkish Studies*, 9(11), 263–282. <https://doi.org/10.7827/TurkishStudies.7454>
- İrdem, C. (2022). Türkiye buğday verimindeki değişimlerin sıcaklık ve yağış koşulları ile ilişkileri. *Turkish Studies - Social Sciences*, 17(3), 377–392. <https://doi.org/10.7827/TurkishStudies.58107>
- Javanmard, M. E., & Ghaderi, S. F. (2022). A hybrid model with applying machine learning algorithms and optimization model to forecast greenhouse gas emissions with energy market

- data. *Sustainable Cities and Society*, 82, Article 103886. <https://doi.org/10.1016/j.scs.2022.103886>
- Jin, Y., & Sharifi, A. (2025). Machine learning for predicting urban greenhouse gas emissions: A systematic literature review. *Renewable and Sustainable Energy Reviews*, 215, Article 115625. <https://doi.org/10.1016/j.rser.2025.115625>
- Kan Çelik, A. (2026). Once upon a code – The digital evolution of traditional narrative (artificial intelligence) [Bir varmış bir kodmuş - geleneksel masal anlatısının dijital evrimi (yapay zekâ)]. *Turkish Studies - Language and Literature*, 21(2), 2607–2635. <https://doi.org/10.7827/TurkishStudies.88760>
- Kanat, E. (2020). Determination of optimum artificial neural network in the stock market. *Turkish Studies - Economics, Finance, Politics*, 15(1), 239–252. <https://doi.org/10.29228/TurkishStudies.4003>
- Karadağ, E. (2025). Kamusal alanda dijital destekli heykel uygulaması örneği: Blaundos heykel uygulaması. *Turkish Studies*, 20(3), 1609–1624. <https://doi.org/10.7827/TurkishStudies.86486>
- Karakuş, N., Eren Ökten, C., & Gedik, K. (2025). İki dillilik ve yapay zekâ: Diller ötesilik tespiti için kavramsal bir model önerisi. *Turkish Studies - Language and Literature*, 20(2), 1167–1188. <https://doi.org/10.7827/TurkishStudies.79747>
- Karataş, A. (2014). Toplumda çevre bilincinin yaygınlaştırılmasında sivil toplum kuruluşlarının rolü: Türkiye örneği. *Turkish Studies*, 9(2), 855–867. <https://doi.org/10.7827/TurkishStudies.6257>
- Katırcıoğlu, S. T. (2014). International tourism, energy consumption, and environmental pollution: The case of Turkey. *Renewable and Sustainable Energy Reviews*, 36, 180–187. <https://doi.org/10.1016/j.rser.2014.04.058>
- Kaufman, S., Rosset, S., Perlich, C., & Stitelman, O. (2012). Leakage in data mining: Formulation, detection, and avoidance. *ACM Transactions on Knowledge Discovery from Data*, 6(4), 1–21. <https://doi.org/10.1145/2382577.2382579>
- Kayaalp, A., & Gürbüz, M. (2025). Coğrafi bilgi sistemleri (CBS) ve uzaktan algılama teknikleri kullanılarak Nil Nehri Deltası sağ sahil bölgesinde arazi örtüsü değişim dinamiklerinin tespiti. *Turkish Studies*, 20(3), 1645–1666. <https://doi.org/10.7827/TurkishStudies.82355>
- Kazel, E. (2022). Ekolojik sürdürülebilirlik açısından İstanbul’da sıfır atık yönetimi. *Turkish Studies - Social Sciences*, 17(5), 841–861. <https://doi.org/10.7827/TurkishStudies.64078>
- Keleş, A. (2018). Derin öğrenme ve sağlık alanındaki uygulamaları. *Turkish Studies - Information Technologies & Applied Sciences*, 13(21), 113–127. <https://doi.org/10.7827/TurkishStudies.14189>
- Keleş, A., & Keleş, A. (2017). BİDEMAT - zeki öğretim sistemi. *Turkish Studies - International Periodical for the Languages, Literature and History of Turkish or Turkic*, 12(6), 547–564. <https://doi.org/10.7827/TurkishStudies.11547>
- Keleş, A., & Keleş, A. (2018). Nesnelerin internetinin getirdiği yenilikler ve sorunları. *Turkish Studies - Information Technologies & Applied Sciences*, 13(13), 53–66. <https://doi.org/10.7827/TurkishStudies.13872>
- Keleş, A., Keleş, A., & Akçetin, E. (2017). Pazarlama alanında yapay zekâ kullanım potansiyeli ve akıllı karar destek sistemleri. *Turkish Studies - International Periodical for the Languages, Literature and History of Turkish or Turkic*, 12(11), 109–124. <https://doi.org/10.7827/TurkishStudies.12022>

- Kızıldağ, H. (2023). Yapay zekâ bir masal yaratıcısı/anlatıcısı olabilir mi?: ChatGPT masalları. *Turkish Studies - Language and Literature*, 18(3), 1759–1775. <https://doi.org/10.7827/TurkishStudies.71763>
- Koçakoğlu, M. A., & Koçakoğlu, Ö. (2025). Bir yapay zeka denemesi: BRICS-Türkiye ülkelerinin ortak para birimi “The Unit”in uygulanabilirliği üzerine bir analiz. *Turkish Studies - Economics, Finance, Politics*, 20(Ö1), 739–757. <https://doi.org/10.7827/TurkishStudies.83867>
- Korkmazıyürek, B., Kahraman, S., & Polat, E. (2022). Dirençli kentlerin harcı: Dirençli kentsel hareketlilik. *Turkish Studies - Social Sciences*, 17(4), 665–681. <https://doi.org/10.7827/TurkishStudies.62946>
- Köksal, O., & Zorlu Kale, B. N. (2025). Integration of technology in the teaching of English as a foreign language: A review study. *Turkish Studies - Language and Literature*, 20(3), 2231–2240. <https://doi.org/10.7827/TurkishStudies.82557>
- Kubar, Y., & Kıl, M. (2022). Çevresel Kuznets eğrisi hipotezinin geçerliliğinin sınanması: Kırılgan sekizli ve G7 ülkeleri uygulaması. *Turkish Studies - Economy*, 17(4), 1043–1062. <https://doi.org/10.7827/TurkishStudies.61972>
- Leerbeck, K., Bacher, P., Junker, R. G., Goranović, G., Corradi, O., Ebrahimi, R., Tveit, A., & Madsen, H. (2020). Short-term forecasting of CO2 emission intensity in power grids by machine learning. *Applied Energy*, 277, Article 115527. <https://doi.org/10.1016/j.apenergy.2020.115527>
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. *Advances in Neural Information Processing Systems*, 30, 4765–4774. <https://proceedings.neurips.cc/paper/2017/hash/8a20a8621978632d76c43dfd28b67767-Abstract.html>
- Lundberg, S. M., Erion, G., Chen, H., DeGrave, A., Prutkin, J. M., Nair, B., Katz, R., Himmelfarb, J., Bansal, N., & Lee, S.-I. (2020). From local explanations to global understanding with explainable AI for trees. *Nature Machine Intelligence*, 2(1), 56–67. <https://doi.org/10.1038/s42256-019-0138-9>
- Mazlum, Ö., & Mazlum, F. M. (2025). Tasarımın dünü, bugünü, geleceği: Yapay zekâ (YZ) çağında tasarımın kavramsal ve estetik dönüşümü. *Turkish Studies*, 20(3), 1721–1739. <https://doi.org/10.7827/TurkishStudies.86478>
- Menteşe, S., & Koca, S. (2025). Eskişehir ilinin biyoklimatik konfor özelliklerinin değerlendirilmesi. *Turkish Studies*, 20(1), 469–482. <https://doi.org/10.7827/TurkishStudies.78261>
- Molnar, C. (2022). *Interpretable machine learning: A guide for making black box models explainable* (2nd ed.). <https://christophm.github.io/interpretable-ml-book>
- Neuberg, L. G. (2003). Causality: Models, reasoning, and inference, by Judea Pearl, Cambridge University Press, 2000 [Review of the book *Causality: Models, reasoning, and inference*, by J. Pearl]. *Econometric Theory*, 19(4), 675–685. <https://doi.org/10.1017/S0266466603004109>
- Odacıoğlu, C. (2022). Dijital dönüşümün mütercim tercümanlık bölümlerine yansımaları bağlamında “çeviride bilgi teknolojileri ve araçları” adlı bir ders önerisi. *Turkish Studies - Language and Literature*, 17(4), 1367–1376. <https://doi.org/10.7827/TurkishStudies.62915>

- Ölçer, M. (2025). Yapay zekâ ile edebî metin çözümlemesi ve çeviri kalite değerlendirmesi: Modern Kore edebiyatı üzerine bir vaka analizi. *Turkish Studies - Language and Literature*, 20(4), 2931–2948. <https://doi.org/10.7827/TurkishStudies.87757>
- Önen, L. (2025). AI-supported image education in drawing: Adaptive learning environments – Personalized systems modeling student style development and generating feedback. *AIS3, Artificial Intelligence Studies in Society, Science, and Systems*, 1(1), 68–81.
- Özdemir, A. (2025). Görsel sanatlarda yapay zekâ-dijital sanat. *Turkish Studies*, 20(4), 2585–2602. <https://doi.org/10.7827/TurkishStudies.87601>
- Özdemir, A. (2026). The intersection of digital art and artificial intelligence: New aesthetic paradigms and theoretical approaches [Dijital sanat ve yapay zekânın kesişimi yeni estetik paradigmlar ve kuramsal yaklaşımlar]. *Turkish Studies*, 21(1), 1457–1486. <https://doi.org/10.7827/TurkishStudies.87600>
- Özen, A., Ülger, M., & Kıdemli, M. (2024). Türkiye’de insani gelişme, kentleşme, sanayinin gelişimi, tarımsal gelişme ve karbon emisyonu ilişkisi. *Turkish Studies - Economics, Finance, Politics*, 19(4), 1431–1446. <https://doi.org/10.7827/TurkishStudies.77741>
- Pata, U. K. (2018). The influence of coal and noncarbohydrate energy consumption on CO2 emissions: Revisiting the environmental Kuznets curve hypothesis for Turkey. *Energy*, 160, 1115–1123. <https://doi.org/10.1016/j.energy.2018.07.095>
- Pearl, J. (2009). Causal inference in statistics: An overview. *Statistics Surveys*, 3, 96–146. <https://doi.org/10.1214/09-SS057>
- Pınarcıoğlu, N. Ş. (2018). İklim değişikliği müzakerelerinde geline nokta: Paris Anlaşması ve sonrası. *Turkish Studies*, 13(23), 211–224. <https://doi.org/10.7827/TurkishStudies.14226>
- Ravanoğlu, G. A. (2020). Environmental Kuznets curve hypothesis in Eurasian Economic Union validity: Panel data analysis. *Turkish Studies - Economy*, 15(1), 491–500. <https://doi.org/10.29228/TurkishStudies.41729>
- Romya Bilgin, K., & Küçükşabanoğlu, Z. (2023). ABD’nin yeni güç stratejisinde yapay zekâ. *Turkish Studies - Economics, Finance, Politics*, 18(1), 273–289. <https://doi.org/10.7827/TurkishStudies.63490>
- Rufaioglu, S. B., Ismael, A. M., Kaplan, F., & Bilgili, A. V. (2025). Comparative evaluation of machine learning algorithms for greenhouse gas emission forecasting: A case study of Turkey (2012–2021). *Environmental Monitoring and Assessment*, 197(10), Article 1075. <https://doi.org/10.1007/s10661-025-14496-3>
- Sağır, H., & Çakır, K. (2026). Ekolojik sanatın kültürel ve politik işlevi: Kamu bilinci üretiminden Taraflar Konferansları (COP) bağlamında çevre politikalarına yansımaları. *Turkish Studies*, 21(2), 3277–3334. <https://doi.org/10.7827/TurkishStudies.87736>
- Sakin, İ., & Türk, Z. (2025). Teknolojiye hazırlık düzeyi ve kullanım algılarının muhasebde yapay zekanın benimseme düzeyine etkilerinin tespiti. *Turkish Studies - Economics, Finance, Politics*, 20(2), 901–919. <https://doi.org/10.7827/TurkishStudies.79592>
- Sandıkcı, Y. T., & Soy, S. (2026). Artificial intelligence and crisis communication: A qualitative analysis within the framework of the technology acceptance model (TAM) in public relations [Yapay zekâ ve kriz iletişimi: Halkla ilişkilerde teknoloji kabullenme modeli (TAM) bağlamında nitel bir analiz]. *Turkish Studies*, 21(2), 3715–3787. <https://doi.org/10.7827/TurkishStudies.88029>

- Sarıbaşı, S. (2025). Yapay zekâ çağında mitin dijital mitosferdeki edebi yeniden yazımı: Kültürel bellek ve anlatısal dönüşümler. *Turkish Studies - Language and Literature*, 20(3), 1939–1962. <https://doi.org/10.7827/TurkishStudies.82517>
- Serçemeli, M. (2018). Muhasebe ve denetim mesleklerinin dijital dönüşümünde yapay zekâ. *Turkish Studies - Economics, Finance, Politics*, 13(30), 369–386. <https://doi.org/10.7827/TurkishStudies.14373>
- Sert, M. F. (2026). Exploring the determinants of global income inequality using an ensemble learning, explainable artificial intelligence, and causal inference-based methodology [Topluluk öğrenmesi, açıklanabilir yapay zekâ ve nedensel analiz tabanlı bir metodoloji ile küresel gelir eşitsizliğinin belirleyicilerinin keşfi]. *Turkish Studies - Economics, Finance, Politics*, 21(2), 3523–3566. <https://doi.org/10.7827/TurkishStudies.87348>
- Shafiei, S., & Salim, R. A. (2014). Non-renewable and renewable energy consumption and CO2 emissions in OECD countries: A comparative analysis. *Energy Policy*, 66, 547–556. <https://doi.org/10.1016/j.enpol.2013.10.064>
- Strobl, C., Boulesteix, A.-L., Zeileis, A., & Hothorn, T. (2007). Bias in random forest variable importance measures: Illustrations, sources and a solution. *BMC Bioinformatics*, 8, Article 25. <https://doi.org/10.1186/1471-2105-8-25>
- Süar Oral, S. (2021). Çevresel sürdürülebilirlik ideolojisinin mitoloji temelli popüler medya içeriklerinde kullanılması: *Ragnarok* televizyon dizisi örneği. *Turkish Studies - Language and Literature*, 16(3), 1667–1697. <https://doi.org/10.7827/TurkishStudies.52298>
- Terzioğlu, M., Ersoy Bozcuk, A., Ünal Uyar, G. F., Kaya, N., Tutcu, B., & Dursun, G. D. (2026). Machine learning classification of return on equity from sustainability reporting and corporate governance metrics: A SHAP-based explanation. *Sustainability*, 18(1), Article 194. [DOI eklenmeli]
- Tetik Küçükkelçi, D. (2025). The mediating role of AI anxiety in the relationship between psychological resilience and social appearance anxiety. *Turkish Studies*, 20(3), 1943–1959. <https://doi.org/10.7827/TurkishStudies.80498>
- Tuğcu, M. S. (2025). Sinemada posthümanizmin ve yapay zekânın temsili: *M3GAN* filmi örneği. *Turkish Studies*, 20(4), 2821–2839. <https://doi.org/10.7827/TurkishStudies.87416>
- Türkiye İstatistik Kurumu. (2026, 27 Mart). *Sera gazı emisyon istatistikleri, 1990–2024* (Haber Bülteni No. 58000). [<https://veriportali.tuik.gov.tr/tr/press/58000/metadata>]
- Ulusoy, T., & Atay, H. (2018). İl özel idarelerinde alternatif finansman kaynakları: Karbon sertifikaları ve kullanımı. *Turkish Studies*, 13(30), 477–494. <https://doi.org/10.7827/TurkishStudies.14303>
- United Nations Framework Convention on Climate Change. (2015). *Turkey's intended nationally determined contribution*. https://www4.unfccc.int/sites/ndcstaging/PublishedDocuments/Turkey%20First/The_INDC_of_TURKEY_v.15.19.30.pdf
- Uygun, S. V. (2026). The use of artificial intelligence in public services related to public order and security: Country examples and recommendations for Türkiye [Asayiş ve güvenlik yönlü kamu hizmetlerinde yapay zeka kullanımı: Ülke örnekleri ve Türkiye için öneriler]. *Turkish Studies*, 21(2), 3789–3825. <https://doi.org/10.7827/TurkishStudies.89247>

- Varol, M. (2025). İlahi imge ve teknolojik insan: Transhümanizm ile dinî geleneklerin Kur'an kursu öğreticileri perspektifinden incelenmesi. *Turkish Studies - Religion*, 20(4), 2291–2308. <https://doi.org/10.7827/TurkishStudies.87056>
- Wager, S., & Athey, S. (2018). Estimation and inference of heterogeneous treatment effects using random forests. *Journal of the American Statistical Association*, 113(523), 1228–1242. <https://doi.org/10.1080/01621459.2017.1319839>
- Yener, S., & Köse, İ. (2023). Treatment prediction using artificial intelligence-integrated chatbots in call centers in medical tourism. *Turkish Studies - Economics, Finance, Politics*, 18(2), 583–597. <https://doi.org/10.7827/TurkishStudies.67267>
- Yıldırım Altun, C. (2025). Geçmiş geleceğe aktarmak: Kültürel miras alanında dijital ikiz oluşturma. *Turkish Studies*, 20(4), 2947–2960. <https://doi.org/10.7827/TurkishStudies.82722>
- Yıldız, M. (2025). Bireysel yenilikçilik ile yapay zekâ tutumu arasındaki ilişki: Gençlik merkezlerinde etkinliklere katılan üniversite öğrencileri üzerine bir araştırma. *Turkish Studies*, 20(Ö1), 1109–1124. <https://doi.org/10.7827/TurkishStudies.86698>
- Yılmaz, E. G. (2020). Doğrudan yabancı yatırımlar, insani gelişme endeksi ve teknoloji ile CO₂ emisyonları ilişkisi analizi. *Turkish Studies - Economy*, 15(3), 1735–1752. <https://doi.org/10.47644/TurkishStudies.41763>
- Yılmaz, O. K. (2025). Avrupa Komisyonu'nun "Avrupa Akıllı Turizm Başkenti" uygulaması ve Türkiye kentlerinin katılımları üzerine bir araştırma. *Turkish Studies*, 20(1), 635–660. <https://doi.org/10.7827/TurkishStudies.77830>
- Zan, N., & Zan, B. U. (2025). Yapay zekâ destekli derin sahtecilik teknolojisinin pedagojik, etik ve toplumsal boyutları. *Turkish Studies*, 20(4), 2961–2983. <https://doi.org/10.7827/TurkishStudies.83049>
- Zenginaloğlu, K. (2026). Culture, ethics and functionality in translation strategies: A comparison of translations produced by artificial intelligence tools and human translators [Çeviri stratejilerinde kültür, etik ve işlevsellik: Yapay zekâ araçlarının ve insan çevirmenin çevirilerinin karşılaştırması]. *Turkish Studies - Language and Literature*, 21(1), 2071–2139. <https://doi.org/10.7827/TurkishStudies.89002>

ETHICAL DECLARATIONS

Research and Publication Ethics

The author(s) declare that this manuscript is an original work prepared in accordance with the principles of scientific research and publication ethics. The manuscript has not been previously published and is not currently under consideration for publication elsewhere. All sources used in the preparation of this study have been properly cited and referenced. The author(s) confirm that the work contains no plagiarism, fabrication, falsification, or manipulation of data. The research findings are presented honestly and transparently in accordance with the principles of academic integrity.

Author Contributions

All authors have significantly contributed to the conception, design, analysis, and preparation of the manuscript. All authors have read and approved the final version of the manuscript and agree to its submission and publication.

Conflict of Interest

The author(s) declare that there is no conflict of interest regarding the publication of this manuscript.

Funding

This research did not receive any specific grant, financial support, or funding from any public, commercial, or non-profit funding agencies.

Artificial Intelligence (AI) Usage Disclosure

During the preparation of this manuscript, artificial intelligence tools may have been used solely for limited purposes such as language editing, translation assistance, and stylistic improvement. Any AI-assisted translations or language corrections were carefully reviewed and verified by the author(s). Artificial intelligence tools were not used to generate the core scientific content, research design, analysis, or scholarly conclusions. All academic responsibility for the content of the manuscript rests entirely with the author(s).

Copyright and Permissions

The author(s) confirm that all necessary permissions for copyrighted materials have been obtained where required and that the manuscript does not violate any intellectual property rights.

Author Approval

All authors confirm that they have read and approved the final version of the manuscript and consent to its submission and publication.

ETİK BEYANLAR

Araştırma ve Yayın Etiği

Yazar(lar), bu makalenin özgün bir çalışma olduğunu ve bilimsel araştırma ve yayın etiği ilkelerine uygun olarak hazırlandığını beyan eder. Makale daha önce herhangi bir yerde yayımlanmamış olup başka bir dergide değerlendirme sürecinde değildir.

Çalışmada kullanılan tüm kaynaklar akademik kurallara uygun biçimde atıflanmıştır. Yazar(lar), çalışmanın intihal, veri uydurma, veri tahrifi veya manipülasyon içermediğini; araştırma bulgularının bilimsel dürüstlük ilkelerine uygun şekilde sunulduğunu beyan eder.

Yazar Katkısı

Tüm yazarlar çalışmanın tasarlanması, yürütülmesi, analizi ve makalenin hazırlanmasına önemli ölçüde katkı sağlamıştır. Tüm yazarlar makalenin son hâlini okuyup onaylamış ve yayımlanmasını kabul etmiştir.

Çıkar Çatışması

Yazar(lar), bu makalenin yayımlanmasına ilişkin herhangi bir çıkar çatışması bulunmadığını beyan eder.

Finansal Destek

Bu araştırma herhangi bir kamu kurumu, ticari kuruluş veya kâr amacı gütmeyen kuruluş tarafından finansal olarak desteklenmemiştir.

Yapay Zekâ Kullanım Beyanı

Makalenin hazırlanması sürecinde yapay zekâ araçlarından yalnızca dil düzenleme, çeviri desteği ve anlatım iyileştirmesi amacıyla sınırlı ölçüde yararlanılmış olabilir. Yapay zekâ araçları tarafından yapılan çeviri ve dil düzenlemeleri yazar(lar) tarafından dikkatle kontrol edilmiştir. Yapay zekâ araçları çalışmanın bilimsel içeriğinin, araştırma tasarımının, analizlerinin veya akademik sonuçlarının oluşturulmasında kullanılmamıştır. Makalenin içeriğine ilişkin tüm akademik sorumluluk yazar(lar)a aittir.

Telif Hakları ve İzinler

Yazar(lar), telif hakkı gerektiren materyaller kullanılmışsa gerekli izinlerin alındığını ve çalışmanın herhangi bir fikrî mülkiyet hakkını ihlal etmediğini beyan eder.

Yazar Onayı

Tüm yazarlar makalenin son hâlini okuduklarını, onayladıklarını ve yayımlanmasını kabul ettiklerini beyan eder.