Uluslararası Yönetim İktisat ve İşletme Dergisi, Cilt 22, Sayı 2, 2026
International Journal of Management Economics and Business, Vol. 22, No. 2, 2026

Araştırma Makalesi / *Research Article*

NATO'NUN KURUCU ÜLKELERİNDE EKONOMİK, ÇEVRESEL VE SOSYAL FAKTÖRLERİN DOĞUMDA BEKLENEN YAŞAM SÜRESİNE ETKİSİ: RASSAL ORMAN REGRESYONU

Süreyya İMRE BIYIKLI[1], Enes ERGİN[2]

ÖZET

Bu çalışmada, kişi başına düşen gayri safi yurt içi hasıla (GSYH), cari sağlık harcamaları (CSH), CO_2 emisyonları (CO_2), $PM_{2.5}$ hava kirliliği (HK) ve kentsel nüfus oranı (KN) değişkenleri, doğrusal regresyon modelleri (OLS) ve Rassal Orman regresyonu (RF) yöntemleri kullanılarak karşılaştırmalı biçimde analiz edilmiştir. 2009–2020 dönemine ait veri seti üzerinden elde edilen bulgular, model performansları açısından önemli farklılıklar ortaya koymaktadır. Doğrusal regresyon modeli sonuçları incelendiğinde, hem zaman etkisinin hem de her bir ülkenin kukla değişkenler vasıtasıyla modele dahil edilmesiyle açıklama gücünün belirgin biçimde arttığı ($R^2 \approx 0.97$) görülmektedir. Bu bulgu, ülkeler arası yapısal farklılıkların yaşam süresi üzerinde kritik rol oynadığını göstermektedir. Rassal orman regresyonu modeli ise daha güçlü bir tahmin performansı sergilemiştir. Özellikle 1000 ağaçlı modelin test setinde en yüksek açıklama gücüne ulaşması ($R^2 \approx 0.82$) ve düşük hata metrikleri üretmesi, doğrusal olmayan yöntemlerin veri içerisindeki karmaşık ilişkileri daha başarılı şekilde yakalayabildiğini göstermektedir. Ayrıca, modelin eğitim ve test performansları arasındaki farkın görece düşük olması, aşırı öğrenme riskinin sınırlı olduğunu ortaya koymaktadır. Değişken önem analizleri, zaman ve sağlık harcamalarının (özellikle gecikmeli etkilerinin) yaşam süresi üzerinde belirleyici olduğunu göstermektedir. Sonuç olarak, elde edilen bulgular doğrusal modellerin açıklayıcı gücüne karşın, Rassal Orman yaklaşımının hem tahmin performansı hem de karmaşık ilişkileri yakalama kapasitesi açısından daha üstün olduğunu ortaya koymaktadır.

Anahtar Kelimeler: *Doğumda Beklenen Yaşam Süresi, Cari Sağlık Harcamaları, PM2.5 Hava Kirliliği, CO_2 Emisyonları, Rassal Orman Regresyonu*

JEL Sınıflandırması: *I15, Q53, C52*

[1] Dr. Öğr. Üyesi, İstanbul Gelişim Üniversitesi, İktisadi, İdari ve Sosyal Bilimler Fakültesi, İstanbul, Türkiye, *simre@gelisim.edu.tr.*

[2] Lisans Öğrencisi Enes Ergin, İstanbul Gelişim Üniversitesi, İktisadi, İdari ve Sosyal Bilimler Fakültesi, İstanbul,Türkiye, *enes.ergin@ogr.gelisim.edu.tr.*

Bu makaleye yapılacak atıf: İmre Bıyıklı, S., Ergin, E. (2026). NATO'nun kurucu ülkelerinde ekonomik, çevresel ve sosyal faktörlerin doğumda beklenen yaşam süresine etkisi: Rassal orman regresyonu. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 22(2), 652-677. https://doi.org/10.17130/ijmeb.1696579

ISSN:2147-9208 E-ISSN:2147-9194
http://dx.doi.org/10.17130/ijmeb.1696579
Başvuru Tarihi: 05.10.2025, Yayına Kabul Tarihi: 04.02.2026

Bu eser "Creative Commons Alıntı-GayriTicari-4.0 Uluslararası Lisansı" ile lisanslanmıştır.

Uluslararası Yönetim İktisat ve İşletme Dergisi, Cilt 22, Sayı 2, 2026, ss. 652-677
International Journal of Management Economics and Business, Vol. 22, No. 2, 2026, pp. 652-677

THE EFFECTS OF ECONOMIC, ENVIRONMENTAL AND SOCIAL FACTORS ON LIFE EXPECTANCY AT BIRTH IN NATO FOUNDING COUNTRIES: A RANDOM FOREST REGRESSION APPROACH

ABSTRACT

This study comparatively analysed per capita gross domestic product (GDP), current health expenditure (CHE), CO_2 emissions (CO_2), $PM_{2.5}$ air pollution (AP) and the urban population ratio (UPR) using linear regression (OLS) and Random Forest regression (RF) methods. Findings derived from the 2009–2020 dataset revealed significant differences in model performance. Examining the results of the linear regression model revealed that the explanatory power increased significantly ($R^2 \approx 0.97$) when both the time effect and the country-specific dummy variables were included in the model. This indicates that structural differences between countries play a critical role in life expectancy. However, the Random Forest regression model demonstrated stronger predictive performance. Notably, the 1,000-tree model achieved the highest explanatory power ($R^2 \approx 0.82$) and produced low error metrics in the test set, demonstrating the superiority of nonlinear methods in capturing complex relationships within the data. Additionally, the relatively small difference between the model's training and test performance suggests that overfitting is not a significant risk. Variable importance analyses suggest that time and healthcare expenditure (particularly the lagged effects of these factors) are the primary determinants of life expectancy. In conclusion, despite the explanatory power of linear models, the Random Forest regression approach is superior in terms of both predictive performance and the ability to capture complex relationships.

Keywords: *Life Expectancy at Birth, Current Health Expenditures, PM2.5 Air Pollution, CO_2 Emissions, Random Forest Regression*

JEL Classification Codes: *I15, Q53, C52*

EXTENDED SUMMARY

Research Questions & Purpose

This study examines the economic, environmental and social determinants of life expectancy at birth in NATO founding countries. The main research question is whether life expectancy is determined only by linear effects of income, health expenditure, environmental quality and, urbanisation, or whether these relationships also involve non-linear, lagged and interaction-based dynamics. In this context, the study analyses the effects of per capita gross domestic product, current health expenditure, CO_2 emissions, $PM_{2.5}$ air pollution and urban population ratio on life expectancy at birth.

The study differs from much of the existing literature in two main respects. First, it evaluates the determinants of life expectancy by using both linear regression models and a non-linear machine learning approach. Second, it controls for time effects, country-specific structural differences and one-period lagged effects of the explanatory variables. Therefore, the study aims to provide a more comprehensive framework by combining the interpretability of linear models with the predictive capacity of Random Forest regression.

Literature Review

The literature on life expectancy generally focuses on three main groups of determinants: health expenditure, environmental factors and socio-economic indicators. Previous studies frequently emphasise the role of health expenditure in increasing life expectancy, although the magnitude and direction of this effect may differ across countries and periods. Other studies examine the role of income, urbanisation, carbon emissions and air pollution in explaining differences in life expectancy. However, the findings are not entirely homogeneous. While some studies identify significant effects of economic growth and environmental variables, others suggest that these effects may be weak, country-specific or observable only in the long run.

In recent years, machine learning methods have increasingly been used in economic, financial and socio-economic data analysis. Random Forest regression, in particular, has been applied in different research fields because of its ability to capture complex and non-linear relationships. However, studies that combine life expectancy analysis with both econometric models and Random Forest regression remain limited. This study contributes to the literature by comparing linear and non-linear modelling approaches within the same empirical framework.

Methodology

This is an applied quantitative study based on annual panel data covering the 2009–2020 period. The dependent variable is life expectancy at birth. The explanatory variables are per capita gross domestic product, current health expenditure, CO_2 emissions, $PM_{2.5}$ air pollution and urban population ratio. The data were obtained from the World Bank database.

Before model estimation, descriptive statistics, correlation analysis and Variance Inflation Factor analysis were conducted. In order to reduce scale differences among variables, Min–Max normalisation was applied to the numerical variables. One-period lagged values of the explanatory variables were also generated to capture dynamic effects. After constructing lagged variables, the modelling sample covers the 2010–2020 period. The dataset was chronologically divided into a training set covering 2010–2017 and a test set covering 2018–2020 in order to preserve the temporal structure of the data.

Three linear regression specifications were estimated. The first model included current and lagged explanatory variables together with year dummy variables. The second model additionally included country dummy variables to control for structural differences across countries, with one country omitted as the reference category to avoid the dummy variable trap. The third model used a numerical year variable instead of year dummies and was used to evaluate out-of-sample prediction performance. Random Forest regression was then applied using different numbers of trees: 100, 500 and 1,000. Model performance was evaluated using R^2, RMSE, MAE and MAPE. Variable importance analysis and partial dependence plots were also used to interpret the Random Forest results.

Since the study uses secondary macro-level data obtained from an open international database, ethics committee approval was not required.

Results and Conclusions

The linear regression results show that adding country dummy variables substantially increases explanatory power. In particular, Model 2 reaches a high R^2 value of approximately

0.97, indicating that country-specific structural differences play an important role in explaining life expectancy. This finding suggests that health systems, institutional structures and social policy differences should not be ignored when analysing life expectancy.

However, the predictive performance of the linear models is more limited. Model 3 indicates a certain degree of overfitting, as its training performance is considerably higher than its test performance. By contrast, the Random Forest models provide stronger predictive results. Among them, the 1,000-tree model achieves the highest test performance, with a test R^2 value of approximately 0.82 and the lowest error metrics. This result shows that Random Forest regression is more successful in capturing complex and non-linear relationships in the data.

Variable importance results indicate that time is the most influential factor, followed by current and lagged health expenditure. This suggests that life expectancy changes systematically over time and that the effects of health expenditure emerge gradually rather than immediately. Partial dependence plots further show that these relationships are not strictly linear and may involve threshold effects and diminishing marginal returns.

CO_2 emissions have relatively low importance in the Random Forest model. This does not necessarily imply that CO_2 emissions are irrelevant; rather, their effects may appear in the long run and accumulate over time. The relatively short period covered by the dataset may limit the observation of such long-term environmental effects.

Overall, the findings demonstrate that using linear and non-linear methods together provides a richer understanding of the determinants of life expectancy. While linear regression models offer interpretability, Random Forest regression improves predictive performance and captures non-linear relationships. Therefore, the study contributes to the literature both methodologically and empirically by showing the value of combining econometric and machine learning approaches in life expectancy analysis.

1. Giriş

Doğumda beklenen yaşam süresi, bir toplumun genel sağlık düzeyini ve yaşam kalitesini yansıtan önemli bir göstergedir. Ekonomik, sosyal ve çevresel faktörler, bu göstergenin belirlenmesinde kilit rol oynamaktadır. Özellikle kişi başına düşen sağlık harcamalarının yaşam süresi üzerindeki etkileri, literatürde sıklıkla vurgulanmaktadır. Gelir düzeyi ve sağlık harcamalarının yaşam süresi üzerindeki etkilerini inceleyen çalışmalarda, kişi başına düşen gelirin ve sağlık harcamalarının yaşam süresi üzerinde anlamlı bir etkisi olduğu gösterilmiştir (Newhouse, 1992). Bunun yanı sıra, çevresel faktörlerin de yaşam süresi üzerinde önemli bir etkisi bulunmaktadır. PM2.5 partikül maddelerin insan sağlığı üzerindeki olumsuz etkileri küresel ölçekte rapor edilmiştir. Araştırmalar, hava kirliliğinin kardiyovasküler ve solunum yolu hastalıklarını artırarak yaşam süresini kısalttığını göstermektedir (Pope & Dockery, 2006). Ayrıca, kentsel nüfus yoğunluğunun, sağlık hizmetlerine erişimi kolaylaştırarak yaşam kalitesini artırabileceği, ancak aynı zamanda çevresel sorunlara yol açabileceği belirtilmektedir

Yüksek kişi başına düşen GSYH, genellikle daha iyi sağlık hizmetlerine, tedavi imkanlarına ve hastalıkların önlenmesine yönelik politikaların hayata geçirilmesini sağlar. Bu da yaşam süresinin uzamasına katkı sağlar. Ancak, GSYH'nın artması aynı zamanda çevresel faktörlerin bozulmasına yol açabilir. Sanayileşme ve fosil yakıt kullanımı gibi ekonomik geliş-

meler, çevresel kirliliği artırarak PM2.5 oranlarını yükseltir ve dolayısıyla yaşam süresini kısaltabilir (Goklany, 2012). Ekonomik büyüme, sağlık hizmetlerine yapılan yatırımların artmasına olanak sağlasa da çevresel etkiler göz önünde bulundurulmazsa, bu durum olumsuz sonuçlar doğurabilir.

Kentsel nüfus yoğunluğu da yaşam süresini etkileyen bir faktördür. Kentsel alanlarda yaşayan insanlar genellikle daha iyi sağlık hizmetlerine, eğitim olanaklarına ve iş fırsatlarına daha kolay erişebilirler, bu da yaşam kalitesini artırır. Ancak, yoğun nüfus ve sanayileşme, hava kirliliği ve çevresel bozulmanın artmasına neden olabilir. Bu durum, kentsel alanlarda yaşayan bireylerin sağlıklarını olumsuz etkileyebilir. Ayrıca, düşük gelirli kesimler genellikle daha kirli bölgelerde yaşar, bu da sağlık hizmetlerine erişimlerini ve yaşam kalitelerini daha da zorlaştırır. Kentsel nüfus yoğunluğunun etkileri, yaşam süresini artırmaya yönelik olumlu etkiler sağlarken, çevresel bozulmalar ve sağlık eşitsizlikleri de ortaya çıkabilir.

Sonuç olarak, PM2.5 hava kirliliği, kişi başına düşen GSYH ve kentsel nüfus yoğunluğu, yaşam süresi üzerinde hem doğrudan hem de dolaylı etkiler yaratır. Bu faktörlerin birleşimi, toplumların genel sağlık durumunu şekillendirir ve yaşam kalitesini doğrudan etkiler. Sağlık altyapısının güçlendirilmesi ve çevresel etkilerin azaltılması, yaşam süresinin artırılması için önemlidir.

Bu çalışma, doğumda beklenen yaşam süresi (DBYS) üzerinde etkili olan ekonomik, çevresel ve sosyal faktörleri, doğrusal ve doğrusal olmayan yöntemleri birlikte kullanarak kapsamlı bir biçimde analiz etmeyi amaçlamaktadır. Literatürde söz konusu ilişkiler çoğunlukla doğrusal modeller çerçevesinde ele alınırken, bu çalışma değişkenler arasındaki ilişkilerin doğrusal olmayan yapısını da dikkate alarak daha gerçekçi bir analiz sunmaktadır. Bu kapsamda, NATO'nun kurucu ülkeleri gibi yapısal olarak benzer ancak belirli farklılıklar içeren bir ülke grubu üzerinden, yaşam süresini belirleyen faktörler hem zamansal hem de ülkeler arası heterojenlik dikkate alınarak incelenmiştir. Bu yönüyle çalışma, yalnızca değişkenler arası ilişkileri ortaya koymakla kalmayıp, bu ilişkilerin doğrusal olmayan dinamiklerini de analiz ederek literatüre metodolojik açıdan önemli bir katkı sunmaktadır.

Çalışmada, doğumda beklenen yaşam süresini etkileyen temel faktörler; kişi başına düşen gelir (GSYH), cari sağlık harcamaları (CSH), karbon emisyonları (CO_2), $PM_{2.5}$ hava kirliliği (HK) ve kentsel nüfus oranı (KN) değişkenleri çerçevesinde ele alınmaktadır. Bu değişkenlerin hem cari hem de gecikmeli etkileri dikkate alınarak oluşturulan modellerde, zaman ve ülke etkileri kontrol altına alınmıştır. Analiz, öncelikle doğrusal regresyon modelleri ile gerçekleştirilmiş, ardından Rassal Orman regresyonu yöntemi kullanılarak değişkenler arası doğrusal olmayan ilişkiler ve etkileşimler değerlendirilmiştir. Bu yaklaşım, yalnızca hangi değişkenlerin etkili olduğunu değil, aynı zamanda bu etkilerin farklı düzeylerde nasıl değiştiğini ortaya koymayı mümkün kılmaktadır. Böylece çalışma, yaşam süresini belirleyen faktörlerin yapısını daha derinlemesine analiz eden bütüncül bir çerçeve sunmaktadır.

2. Literatür Taraması

Doğumda beklenen yaşam süresi, bireylerin sağlık düzeyini, sosyo-ekonomik refahını ve çevresel koşullarını yansıtan temel bir kalkınma göstergesi olarak kabul edilmektedir. Bu göstergenin belirleyicilerini inceleyen literatür, genel olarak üç ana başlık altında sınıf-

landırılmaktadır: sağlık harcamalarının etkileri, çevresel faktörlerin rolü ve ekonomik-sosyal değişkenlerin katkısı. Bununla birlikte, son yıllarda sağlık ekonomisi literatüründe, makine öğrenmesi algoritmalarına dayalı tahmin modellerinin kullanımının giderek yaygınlaştığı ve bu yöntemlerin geleneksel yaklaşımlara alternatif bir analiz çerçevesi sunduğu görülmektedir.

Birçok çalışma, yaşam süresi üzerindeki en güçlü belirleyici değişkenin sağlık harcamaları olduğunu ortaya koymuştur. Tüylüoğlu & Tekin (2009), çalışmalarında 176 ülkenin 2003 yılına ait iktisadi göstergelerinin sağlık göstergelerini açıklayıcılığını çoklu regresyon analizi ile incelemiştir. Yaptıkları analizlere göre, beklenen yaşam süresi ve bebek ölüm oranı üzerinde sağlık harcamalarının gelir düzeyine göre daha fazla etkili olması, sadece gelir düzeyinin artırılmasına güvenilemeyeceğini göstermektedir.

Linden & Ray (2017), doğumda beklenen yaşam süresi ile kamu ve özel sağlık harcamaları arasındaki ilişkileri, 1970-2012 yılları arasında 34 OECD ülkesi için panel veri ve zaman serisi yöntemlerini kullanarak test etmişlerdir. Ülkeler, GSYH içindeki kamu sağlık harcamalarının payına göre üç kümeye ayrılmıştır. Kamu sağlık harcamalarının GSYH içindeki payının yüksek olduğu ülkeler için eşbütünleşme ilişkisi tespit edilmiştir. Panel VAR modelleri ve etki-tepki analizi ile desteklenen sonuçlar, kamu sağlık harcamaları ile yaşam süresi arasındaki pozitif ilişkinin önemini vurgulamaktadır.

Jaba vd. (2014), 1995-2010 yılları arasında 175 ülkeyi kapsayan bir panel veri analiziyle, sağlık harcamaları ile doğumda yaşam beklentisi arasında anlamlı bir ilişki olduğu sonucunu elde etmişlerdir. Ülke etkileri de anlamlı bulunmuş ve ülkeler arasında önemli farklılıkların varlığı tespit edilmiştir.

Aydın (2020)'ın OECD ülkeleri üzerinde gerçekleştirdiği regresyon analizi sonuçlarına göre, beklenen yaşam süresini en fazla etkileyen faktör sağlık harcamalarıdır. Bu bulgu, sağlık alanına yapılan yatırımların ve hizmetlere ayrılan kaynakların bireylerin yaşam süresi üzerinde önemli bir rol oynadığını göstermektedir.

Akbal (2021), 1980–2018 dönemi için ekonomik büyüme, cari sağlık harcamalarının GSYH içindeki payı ve doğumda beklenen yaşam süresi arasındaki ilişkileri ARDL sınır testi yaklaşımıyla incelemiştir. Elde edilen bulgular, uzun dönemde doğumda beklenen yaşam süresindeki artışın sağlık harcamalarını anlamlı ve güçlü bir biçimde artırdığını (yaklaşık %31.15) göstermektedir. Benzer şekilde, ekonomik büyümedeki artışın da sağlık harcamaları üzerinde pozitif ve istatistiksel olarak anlamlı bir etkisi olduğu tespit edilmiştir.

Rjoub vd. (2021),1960-2018 dönemine ait zaman serisi verilerini kullanarak, Bayer–Hanck eşbütünleşme testi, Fourier Toda–Yamamoto ve Breitung–Candelon nedensellik testlerini uygulayarak Türkiye'de karbon emisyonları, ekonomik büyüme ve yaşam beklentisi arasındaki nedensel ilişkileri incelemektedir. Literatürden farklı olarak, yaşam beklentisi ile CO_2 arasında pozitif bir birlikte hareket etme eğilimi ve yaşam beklentisi ile GSYH arasında farklı ölçeklerde pozitif bir korelasyon bulunmuştur. CO_2'nin yaşam beklentisi ile nedensel bir ilişkisi olduğu, yaşam beklentisi ile GSYH arasında çift yönlü bir nedensellik bulunduğu ve CO_2'nin yaşam beklentisi ile kısa, orta ve uzun vadeli nedensel ilişkileri olduğu tespit edilmiştir. Ayrıca, GSYH'nin yaşam beklentisi ile orta ve uzun vadeli, yaşam beklentisinin ise GSYH ile kısa, orta ve uzun vadeli nedensel ilişkileri olduğu belirlenmiştir.

Börüban & Özgür Güler (2022) tarafından yapılan bu çalışmada, yüksek gelir grubunda yer alan Kanada, Belçika, İngiltere, Almanya, Avusturya, İspanya, İsveç, Fransa, İtalya ve ABD gibi ülkelerde çevresel bozulma, ekonomik durumlar ve demografik değişkenlerin ortalama yaşam süresi üzerindeki etkileri incelenmiştir. Genel bulgulara göre, karbondioksit emisyonlarının yaşam beklentisi üzerinde anlamlı bir etkisi bulunmamıştır. Ancak ülke bazlı analizler yapıldığında, CO_2 emisyonundaki %1'lik bir artışın Kanada, İspanya, Fransa, İtalya ve İsveç gibi bazı ülkelerde yaşam süresini olumsuz etkilediği tespit edilmiştir.

Çakır (2023), yaptığı çalışmada 2005-2019 dönemi için E-7 ülke grubunun kullanıldığı ve yatay kesit bağımlılık ile parametre homojenliğin araştırılmasının ardından panel nedensellik analizini gerçekleştirdiği çalışmasında, tahminler neticesinde doğumda beklenen yaşam süresi ile CO_2 emisyonu arasında çift yönlü bir nedensellik ilişkisinin bulunduğu belirlemiştir.

Ekonomik refah göstergeleri ile yaşam süresi arasındaki ilişkiyi ele alan Panahi & Aleemran (2016), enflasyon, sağlık harcamaları ve kentleşmenin Orta Doğu ve Kuzey Afrika (MENA) ülkelerindeki yaşam beklentisi üzerindeki etkisini 2000-2012 dönemi için panel veri kullanarak bir nedensellik analizi ile gerçekleştirmiştir. Sonuçlara göre, enflasyondaki bir birimlik artış yaşam beklentisini 3,17 birim azaltmıştır. Ayrıca, sağlık harcamaları ve kentleşme değişkenlerindeki bir birimlik artış yaşam beklentisini sırasıyla 0,12 ve 0,37 birim artırmıştır.

Tıraş & Özbek (2020), 1980-2018 dönemine ait 28 OECD ülkesinin verilerini kullanarak kişi başına düşen GSYH, kaba doğum oranı, kentleşme oranı ve kişi başına karbondioksit salınımının doğumda beklenen yaşam süresi üzerindeki etkilerini dinamik panel veri analizi yöntemiyle incelemiştir. Elde edilen sonuçlara göre, kişi başına gelir ile kentleşme oranının yaşam beklentisi üzerinde istatistiksel olarak anlamlı bir etkisi bulunurken, kaba doğum oranı ve CO_2 emisyonlarına ait eşbütünleşme katsayıları anlamlı çıkmamıştır. Ayrıca, kişi başına düşen gelirdeki %1'lik bir artışın yaşam beklentisini yaklaşık %0,007 oranında azalttığı, buna karşılık kentleşmedeki %1'lik bir artışın yaşam süresini %0,27 oranında artırdığı belirlenmiştir.

Son yıllarda, ekonometrik yöntemlerin yanı sıra, makine öğrenmesi algoritmaları da sağlık ve sosyo-ekonomik verilerin analizinde giderek daha yaygın bir şekilde kullanılmaktadır. Bu kapsamda özellikle Rassal Orman Regresyon yöntemi, farklı veri türleri ve araştırma alanlarında uygulanarak esnek ve güçlü bir analiz aracı olarak öne çıkmaktadır. Literatürde, bu yöntemin yalnızca belirli bir konuya özgü olmadığı; farklı disiplinlerde ve çeşitli veri yapıları üzerinde başarıyla uygulanabildiği gösterilmektedir. Bu durum, Rassal Orman Regresyon algoritmasının geniş bir uygulama alanına sahip olduğunu ve farklı araştırma problemlerine uyarlanabilir bir yöntem sunduğunu ortaya koymaktadır.

Demirezen & Çetin (2021), Türkiye elektrik piyasasında Piyasa Takas Fiyatı (PTF)'nın tahmini için makine öğrenmesi yöntemlerinden Rassal Orman Regresyonu (RF) ve Destek Vektör Regresyonu (SVR) yöntemlerini kullanmıştır. Çalışma, EPİAŞ tarafından işletilen Gün Öncesi Piyasası'nda oluşan saatlik PTF değerlerini tahmin etmeyi amaçlamış ve geçmiş PTF değerleri ile gün öncesi piyasasında oluşan işlem hacminin tahmin performansına etkisi incelenmiştir. Analizlerde RMSE, MAE ve MAPE performans kriterleri kullanılmış ve işlem hacminin dahil edildiği Rassal Orman modeli (RFR-2) en iyi tahmin sonuçlarını vermiştir. Çalışma, işlem hacminin PTF tahminlerinde önemli bir değişken olduğunu ortaya koyarken,

literatürde görece daha az kullanılan Rassal Orman yönteminin de PTF tahmini için etkili bir araç olduğunu göstermiştir.

Demirezen (2021), altın fiyatlarının tahmini için ARIMA (Bütünleşik Otoregresif Hareketli Ortalama) ve Rassal Orman Regresyon yöntemlerini karşılaştırmıştır. Çalışmada, altın fiyatlarının geçmiş değerleri her iki modelin tahmin performansını değerlendirmek amacıyla kullanılmıştır. Veri seti, eğitim ve test kümelerine ayrılarak, model yapılarına bağlı olarak tahminler gerçekleştirilmiştir. Performans değerlendirmesi için RMSE ve MAE metrikleri kullanılmış ve her iki kriterde de Rassal Orman Regresyonu yönteminin ARIMA'ya kıyasla daha iyi sonuçlar verdiği belirlenmiştir.

Özkan vd. (2023), 193 ülkenin gelişmişlik düzeyini sınıflandırmak için bir makine öğrenmesi modeli geliştirmiştir. Çalışmada, gelişmişlik düzeyi "Yüksek Gelir", "Üst Orta Gelir", "Alt Orta Gelir" ve "Düşük Gelir" kategorilerine ayrılmış ve bu seviyeleri etkileyen 26 bağımsız değişken Dünya Gelişmişlik İndeksi (WDI) veri tabanından elde edilmiştir. Rastgele Orman yöntemi, değişken önemini belirlemek için kullanılmış ve en önemli değişkenler seçilerek sınıflandırma modelleri oluşturulmuştur. Rastgele Orman algoritmasıyla oluşturulan model, ülkelerin gelişmişlik düzeylerini %70 doğruluk oranıyla sınıflandırmıştır. Bulgular, ergen doğurganlık hızı, toplam doğurganlık oranı ve tarım, orman ve balıkçılık faaliyetlerinin GSYH içindeki payının gelişmişlik düzeylerini etkileyen en önemli değişkenler olduğunu göstermektedir.

Khaidem vd. (2016), hisse senedi fiyatlarının yönünü tahmin etmek amacıyla Rassal Orman Regresyonu algoritmasını kullanmıştır. Çalışmada, borsa verileri ve teknik göstergeler temel alınarak kısa vadeli fiyat hareketlerini doğru bir şekilde sınıflandırmaya yönelik bir model geliştirilmiştir. Modelin performansı doğruluk oranı, precision ve recall gibi metriklerle test edilmiştir. Sonuçlar, Rassal Orman Regresyonu algoritmasının hisse senedi fiyatlarının yönünü tahmin etmede geleneksel yöntemlere kıyasla daha etkili ve güvenilir olduğunu göstermiştir.

Koç Ustalı vd. (2021), Borsa İstanbul 30 Endeksi'nde işlem gören firmaların hisse senedi fiyatlarının tahmini amacıyla Yapay Sinir Ağları (YSA), Rastgele Orman (RO) ve XGBoost algoritmalarını karşılaştırmıştır. Çalışmada, firmaların 2010-2019 yılları arasındaki üçer aylık finansal tablolarından hesaplanan finansal oranlar ile hisse senetlerinin aylık kapanış fiyatlarının üçer aylık ortalamaları kullanılmıştır. Tahmin sonuçları, XGBoost ve Rastgele Orman algoritmalarının birbirine yakın performans sergilediğini, ancak XGBoost algoritmasının en iyi sonucu verdiğini göstermiştir. Ayrıca, her iki modelin de YSA'ya göre daha yüksek doğruluk ve performansa sahip olduğu tespit edilmiştir.

Doğan vd. (2022), finansal zaman serisi tahmini kapsamında Japonya'nın Nikkei 225 ve Amerika'nın S&P500 endekslerinin kapanış değerlerini tahmin etmek amacıyla Destek Vektör Regresyonu (SVR) ve Rassal Orman Regresyonu (RF) yöntemlerini karşılaştırmıştır. Çalışmada, 2016-2021 yılları arasındaki günlük veriler kullanılarak %80 eğitim ve %20 test veri seti oluşturulmuş, performans değerlendirmesi için RMSE, MAPE ve R^2 metrikleri kullanılmıştır. Analiz sonuçları, RF modelinin SVR'ye kıyasla daha düşük hata oranlarına ve daha yüksek doğruluk değerlerine sahip olduğunu göstermiştir.

3. Yöntem

3.1. Rassal Orman Regresyonu

Rassal Orman Regresyonu, birden fazla karar ağacını bir arada kullanarak tahminler yapan güçlü bir ensembl öğrenme yöntemidir (Breiman, 2001). Karar ağaçları, veri setini dallara ayırarak bağımlı değişkeni açıklamaya çalışır. Ancak tek bir karar ağacı genelde aşırı öğrenmeye yatkın olduğu için genelleme performansı sınırlı kalır. Bu sınırlamaları aşmak amacıyla geliştirilen Rassal Orman algoritması, her bir karar ağacını farklı veri alt kümeleriyle eğitir ve tahminleri birleştirerek nihai sonuçları üretir (Hastie vd., 2009). Bu yaklaşım, genelde tahminlerin ortalamasını alarak daha güvenilir sonuçlar elde edilmesini sağlar.

Algoritmanın temelinde, orijinal veri setinden rastgele örneklenen alt kümelerle ağaçlar oluşturulmasını sağlayan bagging (bootstrap aggregating) yöntemi yer alır (Breiman, 2001). Ayrıca, her ağacın düğüm oluşturma sürecinde rastgele bir alt özellik kümesinin seçilmesi, modeldeki rastgeleliği artırır ve ağaçlar arasında bağımsızlık sağlar (Liaw & Wiener, 2002). Bu rastgelelik, modelin aşırı öğrenmeyi önlemesine ve genellenebilirliğini artırmasına yardımcı olur. Özellikle regresyon problemlerinde her ağaç bir tahmin yapar ve bu tahminlerin ortalaması alınarak son tahmin üretilir.

Rassal Orman modelinin performansı, kullanılan hiperparametrelerin optimizasyonuyla artırılabilir. Öne çıkan hiperparametreler arasında ağaç sayısı (n_estimators), maksimum derinlik (max_depth), yaprak düğümdeki minimum örnek sayısı (min_samples_leaf) ve bir düğümün dallanması için gereken minimum örnek sayısı (min_samples_split) yer alır. Daha fazla ağaç genelde doğruluğu artırırken, çok derin ağaçlar aşırı öğrenmeye yol açabilir (Liaw & Wiener, 2002). Bu nedenle, model performansını izlemek için çapraz doğrulama yöntemi kullanılarak hiperparametrelerin optimal değerleri belirlenmelidir (Kohavi, 1995). Çapraz doğrulama, modelin farklı veri alt kümelerinde test edilerek genellenebilirliğini değerlendirir.

Rassal Orman Regresyonu algoritması, modeldeki değişkenlerin önem düzeyini ölçmek için iki önemli metrik sunar: %IncMSE (Mean Squared Error artışı) ve IncNodePurity (Düğüm Saflaştırma). %IncMSE, bir değişkenin modelden çıkarıldığında ortalama kare hatada (MSE) meydana gelen artışı ölçer. Bu metrik, bir değişkenin model doğruluğuna katkısını gösterir; yüksek %IncMSE değerleri, ilgili değişkenin modelin tahmin performansı üzerinde güçlü bir etkiye sahip olduğunu ifade eder. Diğer yandan, IncNodePurity, bir değişkenin karar ağacı boyunca tüm düğümlerde sağladığı toplam hata azalmasını ölçer ve bu da değişkenin modeli saflaştırma derecesini ve hata azaltma etkinliğini yansıtır. Hem %IncMSE hem de IncNodePurity, modelin doğruluğunu artıran ve yorumlanabilirliğini sağlayan değişkenlerin belirlenmesinde önemli bir rol oynar (Liaw & Wiener, 2002).

Rassal Orman, aşırı öğrenmeye dayanıklı olması, heterojen veri setleriyle başarılı bir şekilde çalışabilmesi ve değişken önem düzeylerini belirlemedeki etkinliğiyle güçlü bir modeldir (Breiman, 2001). Ancak, büyük veri setlerinde yüksek hesaplama maliyetine sahip olması ve çok sayıda ağaçla çalışıldığında eğitim süresinin uzaması gibi sınırlamaları da bulunmaktadır (Hastie vd., 2009). Buna rağmen, modelin genelleme yeteneği, geniş uygulama alanlarında etkili bir şekilde kullanılmasını sağlar. Özellikle finans, sağlık ve çevre gibi alanlarda tahminleme ve analiz için Rassal Orman önemli bir araçtır.

Tahmin modellerinin değerlendirilmesi iki temel adımda gerçekleşir: öncelikle tahmin için gerekli veri ön işleme süreçleri tamamlanır, ardından farklı modellerin performansları karşılaştırılır. Performans ölçütleri arasında R^2, MSE, RMSE ve MAE sıkça kullanılmaktadır (Karasu vd., 2018).

Bu ölçütlerden R^2, modelin doğruluğunu temsil eder ve 0 ile 1 arasında değer alır; 1'e yakın değerler modelin yüksek doğrulukla tahmin yaptığını gösterirken, 0'a yakın değerler modelin başarısız olduğunu işaret eder. MSE, tahmin hatalarının karelerinin ortalamasını alarak hesaplanır ve küçük değerleri model doğruluğunun yüksek olduğunu ifade eder. Ancak, hata karelerinin alınması büyük hataların daha fazla cezalandırılmasına yol açar. MSE'nin karekökü olan RMSE, tahmin hatalarını daha anlamlı bir ölçekte sunar ve büyük hatalara karşı daha hassastır. RMSE'nin düşük olması, modelin başarı düzeyinin yüksek olduğunu belirtir. MAE ise tahmin hatalarının mutlak değerlerinin ortalamasını alır ve MSE'ye kıyasla büyük hatalara daha az duyarlıdır. Düşük MAE değeri, modelin tahmin doğruluğunu göstermektedir.

Bu metriklerin formülleri aşağıda verilmiştir (Gökçek vd., 2022):

$$MAE = \frac{1}{n}\sum_{i=1}^{n} |x_i - x| \tag{1}$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(Y_i - \hat{Y}_i)^2} \tag{2}$$

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(Y_i - \hat{Y}_i)^2} \tag{3}$$

$$R^2 = 1 - \frac{\sum(Y_i - \hat{Y}_i)^2}{\sum(Y_i - \bar{Y}_i)^2} \tag{4}$$

Bu çalışmada, farklı ölçeklerdeki değişkenlerin etkili bir şekilde analiz edilmesi için veriler öncelikle normalizasyon işlemine tabi tutulmuştur. Normalizasyon, veri ön işleme sürecinin önemli bir adımı olup, özellikle farklı birimlerdeki ve ölçeklerdeki değişkenlerin aynı düzlemde analiz edilmesini sağlar. Bu işlem, makine öğrenmesi modellerinin performansını artırmak, sonuçları daha anlamlı ve yorumlanabilir hâle getirmek amacıyla yaygın olarak uygulanmaktadır (Dondurmacı & Çınar, 2014).

Her ne kadar Rassal Orman regresyonu algoritması teorik olarak ölçekleme işlemlerine duyarlı bir yöntem olmasa da, veri setinde yer alan değişkenlerin farklı büyüklük aralıklarına sahip olması durumunda, özellikle değişken önem analizleri ve model çıktılarının yorumlanabilirliği açısından normalizasyonun katkı sağladığı değerlendirilmektedir. Bununla birlikte, normalizasyon işlemi veri dağılımını lineer bir dönüşümle yeniden ölçeklendirdiği için değişkenler arası göreli farklılıkları korumakta ve bilgi kaybını minimum düzeyde tutmaktadır. Ancak uç değerlerin varlığı durumunda Min-Max normalizasyonunun bu değerleri yeni ölçeğe sıkıştırarak dağılım üzerinde sınırlı bir bozulmaya yol açabileceği de göz önünde bulundurulmalıdır. Bu çalışmada normalizasyon, özellikle farklı ölçeklerdeki değişkenlerin model içeri-

sinde dengeli biçimde temsil edilmesini sağlamak, modelin öğrenme sürecini stabilize etmek ve elde edilen sonuçların karşılaştırılabilirliğini artırmak amacıyla uygulanmıştır. Bu yönüyle, normalizasyon işlemi doğrusal modellere kıyasla zorunlu bir varsayım olmamakla birlikte, model performansı ve sonuçların yorumlanabilirliği açısından tamamlayıcı bir veri ön işleme adımı olarak değerlendirilmiştir.

$$X_{normalized} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (5)$$

X: Orijinal veri değeri

X_{min}: Veri setindeki minimum değeri

X_{max}: Veri setindeki maksimum değeri

$X_{normalized}$: Normalize olan değeri ifade etmektedir.

Bu çalışma kapsamında Rassal Orman Regresyonu yönteminin tercih edilmesinin temel nedeni, analiz edilen değişkenler arasındaki ilişkilerin yalnızca doğrusal bir yapı sergilememesi ve potansiyel olarak karmaşık, etkileşimli ve doğrusal olmayan bileşenler içermesidir. Geleneksel doğrusal regresyon modelleri, değişkenler arasındaki ilişkileri sabit katsayılar üzerinden ve doğrusal varsayımlar altında açıklarken, Rassal Orman algoritması bu tür varsayımlara ihtiyaç duymadan değişkenler arasındaki doğrusal olmayan ilişkileri ve yüksek dereceli etkileşimleri esnek bir şekilde modelleyebilmektedir. Ayrıca, karar ağaçlarına dayalı yapısı sayesinde model spesifikasyon hatalarına karşı daha dayanıklı olması ve değişkenler arası karmaşık örüntüleri veri içerisinden doğrudan öğrenebilmesi önemli bir avantaj sağlamaktadır. Bunun yanı sıra, bootstrap örnekleme ve rastgele değişken seçimi mekanizmaları sayesinde aşırı öğrenmeye karşı dirençli bir yapı sunması ve yüksek genelleme kabiliyeti göstermesi, yöntemin bu çalışma kapsamında tercih edilmesinde belirleyici olmuştur. Bu yönüyle Rassal Orman, özellikle doğrusal model varsayımlarının yetersiz kalabileceği durumlarda daha güvenilir ve esnek bir tahmin çerçevesi sunmaktadır.

4. Uygulama

NATO'nun kurucu ülkeleri olan Belçika, Kanada, Danimarka, Fransa, İzlanda, İtalya, Lüksemburg, Hollanda, Norveç, Portekiz, Birleşik Krallık ve Amerika Birleşik Devletleri; II. Dünya Savaşı sonrasında demokratik, ekonomik ve askeri iş birliklerini kurumsallaştırmış, benzer kalkınma modelleri benimsemiş gelişmiş ülkelerdir. Bu ülkeler, sağlık altyapısı, kişi başına düşen gelir düzeyi, çevresel düzenlemeler ve kentleşme politikaları bakımından belirli bir standarda sahip olmalarına rağmen, doğumda beklenen yaşam süresi açısından birbirinden farklı sonuçlar göstermektedir. Söz konusu ülkeler arasındaki bu farklılıkların, ekonomik, çevresel ve sosyal göstergelerle açıklanabilir olup olmadığını analiz etmek, karşılaştırmalı bir değerlendirme yapılmasını mümkün kılmaktadır. Ayrıca, bu ülkelerin istatistiksel verilerinin güvenilir ve erişilebilir olması, çalışmanın bilimsel geçerliliğini artırmakta ve uluslararası karşılaştırmalar açısından da önemli bir avantaj sunmaktadır.

Bu çalışmada NATO'nun kurucu ülkeleri arasında ekonomik, çevresel ve sosyal faktörlerin doğumda beklenen yaşam süresi üzerindeki etkilerini incelemek amacıyla hem ekonometrik yöntemler hem de makine öğrenmesi yaklaşımları birlikte kullanılmıştır.2009-2020 dönemine ait yıllık veriler kullanılarak, çevresel faktörler (PM2.5 hava kirliliği, CO_2 emisyonları), ekonomik faktörler (kişi başına düşen GSYH, cari sağlık harcamaları) ve sosyal faktörler (kentsel nüfus oranı) ile doğumda beklenen yaşam süresi arasındaki ilişkiler analiz edilmiştir.

Analiz kapsamında öncelikle doğrusal ilişkileri incelemek amacıyla En Küçük Kareler (EKK-OLS) yöntemi ile farklı doğrusal regresyon modelleri kurulmuş ve böylece zaman etkileri, ülke etkileri ve bağımsız değişkenlerin gecikmeli değerleri modele dahil edilmiştir. Böylece hem ülkeler arası yapısal farklılıklar hem de değişkenlerin zaman içindeki dinamik etkileri kontrol edilmiştir.

Bunun yanı sıra, değişkenler arasındaki doğrusal olmayan ilişkileri ortaya koymak ve modelin tahmin performansını artırmak amacıyla Rassal Orman regresyonu yöntemi uygulanmıştır. Model performansı eğitim ve test setleri üzerinden R^2, RMSE, MAE, MAPE kriterleri kullanılarak değerlendirilmiş, aşırı öğrenme (overfitting) sorunu eğitim ve test performanslarının karşılaştırılması yoluyla analiz edilmiştir. Ayrıca, değişkenlerin göreli önem düzeyleri ve bağımlı değişken üzerindeki marjinal etkileri, değişken önem grafikleri ve kısmi bağımlılık (partial dependence) analizleri ile incelenmiştir. Veri seti, Dünya Bankası (World Bank) veri tabanından temin edilmiş olup, analizler R programlama diliyle gerçekleştirilmiştir.

4.1. Veri Seti

Bu çalışmada, doğumda beklenen yaşam süresi (DBYS) ile ilişkili bir dizi değişken incelenmiştir. Bu değişkenler, toplumların sağlık durumu ve çevresel faktörlerle olan etkileşimlerini anlamak amacıyla kullanılmıştır. Bağımlı değişken olan doğumda beklenen yaşam süresi (DBYS), yıl cinsinden ifade edilmektedir. Bu değişken, bir bireyin doğduğunda beklenen ortalama yaşam süresini temsil eder. Yaşam süresi, sağlık hizmetlerine erişim, yaşam kalitesi ve çevresel faktörler gibi etmenlerden etkilenebilir. Sağlık koşullarının iyileştirilmesi, yaşam süresinin uzamasına yol açabilmektedir. Hava kalitesini temsil eden PM2.5 hava kirliliği değişkeni (HK), metreküp başına mikrogram(birimiyle ifade edilmektedir. PM2.5, havada bulunan ince partikülleri ifade eder ve hava kirliliğinin bir ölçütüdür. Yüksek PM2.5 seviyeleri, solunum ve kardiyovasküler hastalıklar gibi sağlık sorunlarıyla ilişkilidir ve bu durum doğrudan yaşam süresini olumsuz etkileyebilir. Çevresel göstergelerden biri olan kişi başına CO_2 emisyonu (CO_2), ton CO_2 eşdeğeri kişi başına (tCO_2e/capita) olarak ölçülmektedir. Bu değişken, bir ülkenin yıllık toplam karbondioksit emisyon miktarını gösterir. Karbon emisyonları, iklim değişikliği ve çevresel bozulma gibi sorunlara yol açarak dolaylı yoldan yaşam süresi üzerinde etkili olabilir. Cari sağlık harcamaları (CSH) ise GSYH'nin yüzdesi (%) olarak tanımlanmaktadır. Bir ülkenin sağlık sektörüne yaptığı yıllık harcamalar, sağlık hizmetlerinin kalitesini ve erişilebilirliğini yansıtır. Yüksek sağlık harcamaları, genellikle daha iyi sağlık hizmetlerine ve dolayısıyla daha uzun yaşam süresine yol açabilir. Sosyal bir gösterge olarak ele alınan kentsel nüfus oranı (KN), toplam nüfus içindeki payı itibariyle yüzde (%) cinsinden ifade edilmektedir. Toplam nüfusun ne kadarının şehirlerde yaşadığını belirten bu değişken, şehirleşmenin sağlık hizmetlerine erişim, yaşam koşulları ve çevresel etmenler üzerindeki etkilerini gösterir. Şehirleşme oranı arttıkça, yaşam süresi üzerinde pozitif bir etki gözlemlenebilir. Ekonomik değişkenlerden

kişi başına gayri safi yurt içi hasıla (GSYH), cari ABD doları cinsinden (current US$) ölçülmektedir. Bir ülkenin ekonomik refah düzeyini ölçen bu değişken, yüksek kişi başına GSYH ile genellikle daha iyi yaşam standartları ve sağlık koşulları arasında güçlü bir ilişki bulunduğunu ortaya koymaktadır. Ekonomik refah, dolaylı olarak yaşam süresini etkileyebilir.

Bu değişkenlerin incelenmesi, yaşam süresi üzerinde çevresel, sağlık ve ekonomik faktörlerin nasıl etkileşimde bulunduğunu anlamada önemli bir rol oynamaktadır. Model kurulum aşamasına geçmeden önce, değişkenlere ilişkin tanımlayıcı istatistikler hesaplanmış, değişkenler arasındaki ilişkilerin incelenmesi amacıyla korelasyon matrisi grafiği elde edilmiş ve çoklu doğrusal bağlantı sorununu değerlendirmek üzere VIF analizi uygulanmıştır.

Tablo 1: Değişkenlere İlişkin İstatistiksel Bilgiler

Değişkenler	Min	1.Çeyrek	Medyan	Ortalama	3.Çeyrek	Max
DBYS	76,98	80,70	81,45	81,29	82,20	83,50
CO_2	3,962	5,794	8,817	9,802	12,219	22,119
GSYH	19,216	40,889	47,638	54,430	60,488	123,679
CSH	5,070	8,908	10,135	10,202	10,795	18,756
KN	59,96	80,11	82,25	83,08	89,96	98,08
HK	5,106	7,820	10,171	10,601	12,720	21,335

Tablo 1'den elde edilen sonuçlar değerlendirildiğinde; DBYS için minimum değer 76,98 yıl iken maksimum değer 83,50 yıldır. Medyan 81,45 yıl ve ortalama 81,29 yıl olarak hesaplanmıştır. Bu dağılım, NATO kurucu ülkelerinin doğumda beklenen yaşam süresinin genel olarak yüksek olduğunu ve ülkeler arasındaki farklılıkların sınırlı olduğunu göstermektedir. Ancak, minimum ve maksimum değerler arasındaki fark, bazı ülkelerin yaşam süresi açısından diğerlerinden daha avantajlı veya dezavantajlı olabileceğini işaret etmektedir.

GSYH değişkeni için minimum değer 19,216 dolar, maksimum değer ise 123,679 dolar olarak belirlenmiştir. Ortalama gelir seviyesi 54,430 dolar olup, medyan değer 47,638 dolardır. Bu, ülkeler arasında gelir dağılımında önemli farklılıklar olduğunu göstermektedir. 1. ve 3. çeyrek değerleri, gelir düzeyinin büyük bir kısmının orta seviyede yoğunlaştığını işaret etmektedir.

CSH değişkeni için minimum sağlık harcaması 5,07 birim iken maksimum 18,76 birimdir. Ortalama harcama 10,20 birimdir. 1. ve 3. çeyrek değerlerine bakıldığında, sağlık harcamalarının çoğunlukla ortalama değer etrafında yoğunlaştığı görülmektedir. Bu durum, bazı ülkelerde sağlık harcamalarının diğerlerine kıyasla belirgin şekilde yüksek olabileceğini göstermektedir.

KN değişkeni ise minimum %59,96 ve maksimum %98,08 arasında değişmektedir. Ortalama %83,08 olarak hesaplanmış, medyan değer ise %82,25'tir. Kentsel nüfus oranının yüksek olması, çoğu NATO kurucu ülkesinde şehirleşmenin ileri düzeyde olduğunu göstermektedir. Ancak, minimum değer, kırsal nüfusun bazı ülkelerde hâlâ önemli bir yer tuttuğunu işaret etmektedir.

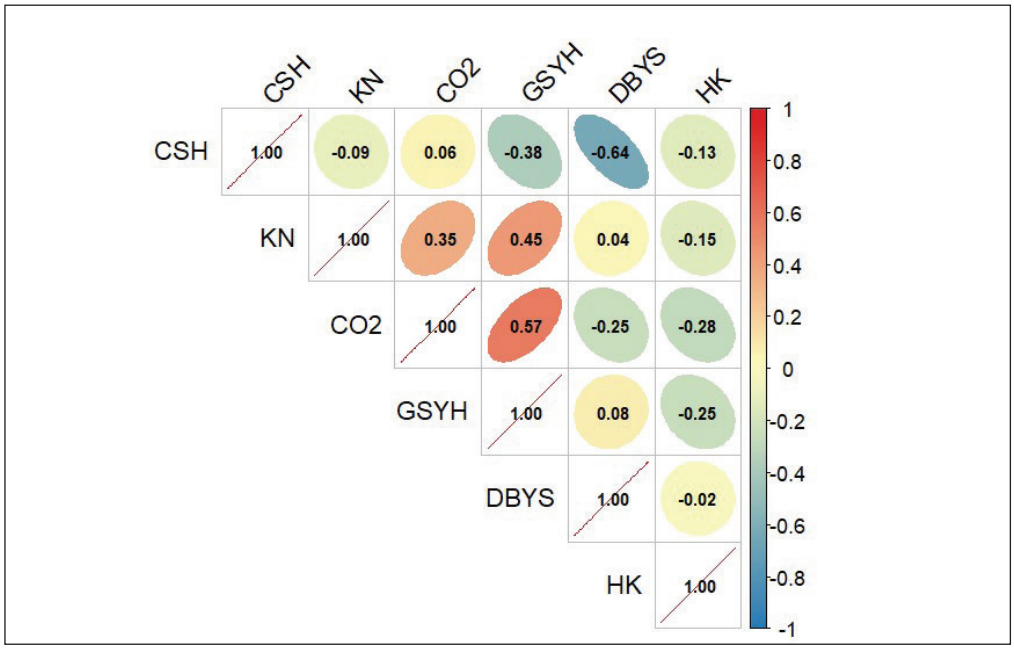
HK değerleri 5,106 ile 21,335 arasında değişmektedir. Ortalama değer 10,601 olup, hava kirliliğinin genellikle orta seviyelerde seyrettiği anlaşılmaktadır. Ancak maksimum değerin oldukça yüksek olması, bazı ülkelerde hava kirliliğinin ciddi bir sorun olduğunu göstermektedir.

CO_2 ise 3,962 ile 22,119 arasında değişmektedir. Ortalama 9,802 olarak hesaplanmış ve medyan değer 8,817'dir. Bu değerler, karbon emisyonlarının ülkeler arasında geniş bir varyasyona sahip olduğunu ve ekonomik faaliyetlerin çevresel etkilerini yansıttığını göstermektedir.

Çalışmada bağımsız değişkenler arasındaki olası çoklu doğrusal bağlantı sorununu tespit etmek amacıyla korelasyon analizi ve Varyans Şişirme Faktörü (Variance Inflation Factor-VIF) analizi gerçekleştirilmiştir. Yüksek korelasyon ve yüksek VIF değerleri, regresyon katsayılarının güvenirliliğini ve istatistiksel anlamlılığını olumsuz etkileyebilmektedir. Bu nedenle özellikle doğrusal regresyon modellerinde tahmin sonuçlarının sağlıklı şekilde yorumlanabilmesi için değişkenler arasındaki ilişki yapısının incelenmesi önemlidir.

Çalışmada kullanılan değişkenlere ait korelasyon matris grafiği aşağıda sunulmuştur.

Şekil 1: Değişkenler Arasındaki Korelasyon Dereceleri



Korelasyon matrisi incelendiğinde, hava kirliliği (HK) ile kişi başına düşen GSYH arasında orta düzeyde pozitif bir ilişki ($r \approx 0.57$) olduğu görülmektedir. Bu bulgu, artan ekonomik faaliyetlerin üretim, enerji tüketimi ve sanayileşme yoluyla çevresel baskıları artırabileceğine işaret etmektedir. Ancak bu ilişkinin ülkeler arasında homojen olmadığı ve özellikle gelişmiş ülkelerde çevre politikaları ve temiz teknolojiler nedeniyle zayıflayabileceği değerlendirilmektedir. Bu durum, ilişkinin doğrusal olmayabileceğini ve ülke bazlı farklılıklar içerebileceğini göstermektedir.

Korelasyon matrisinde CSH ile DBYS arasında negatif bir ilişki ($r \approx -0.64$) gözlenmiştir. Bununla birlikte bu bulgunun, ülkeler arası heterojenlik ve bazı gözlemlerde yüksek sağlık harcamalarına rağmen düşük yaşam süresi değerlerinden kaynaklanabileceği düşünülmektedir. Bu nedenle korelasyon analizi nedensel ilişkiyi tam olarak yansıtmakta yetersiz kalabilmektedir. Nitekim Rassal Orman regresyonu modeli ve kısmi bağımlılık grafikleri, sağlık harcamalarının yaşam süresi üzerindeki etkisinin doğrusal olmadığını ve belirli bir seviyeden sonra azalan marjinal getiri içerdiğini göstermektedir.

Benzer şekilde, kentsel nüfus oranı (KN) ile DBYS arasında oldukça zayıf bir doğrusal ilişki ($r \approx 0.04$) bulunmasına rağmen, Rassal Orman regresyonu modelinde bu değişkenin görece önemli olması, etkisinin doğrusal olmayan ve diğer değişkenlerle etkileşim içinde ortaya çıktığını göstermektedir. Özellikle kentleşmenin sağlık harcamaları, gelir düzeyi ve çevresel faktörlerle birlikte değerlendirilmesi gerektiği anlaşılmaktadır. Değişkenler için hesaplanan VIF değerleri sonuçları Tablo 2'de sunulmuştur.

Tablo 2: VIF Değerleri

CO_2	GSYH	CSH	KN	HK
1,731	2,261	1,404	1,2751	0,153

Korelasyon analizini desteklemek amacıyla gerçekleştirilen VIF analizinin sonuçlarına göre, tüm değişkenler için VIF değerlerinin kabul edilebilir sınırlar içinde kaldığı görülmüştür(genellikle VIF<5). Bu bulgu, modelde yer alan bağımsız değişkenler arasında ciddi çoklu doğrusal bağlantı sorunu bulunmadığını ve regresyon katsayılarının güvenilir bir şekilde yorumlanabileceğini göstermektedir.

4.2. Veri Ön İşleme

Değişkenler arasındaki ölçek farklılıkları, analiz öncesinde normalizasyon işleminin gerekliliğini ortaya koymaktadır. Bu işlem, değişkenlerin aynı ölçek içerisinde yer almasını sağlayarak modelin tüm değişkenlerden eşit katkı almasını ve analiz sonuçlarının daha güvenilir olmasını hedeflemektedir. Normalizasyon işlemi sonrası, tüm değişkenler aynı ölçek aralığında yer almış ve bu durum, modelin performansını optimize etmede önemli bir rol oynamıştır.

Zaman bağımlılığını dikkate almak amacıyla, bağımsız değişkenlerin bir dönem gecikmeli değerleri oluşturulmuştur. Gecikmeli değişkenler, her ülke için ayrı ayrı hesaplanmıştır. Elde edilen bu değişkenler, modelin dinamik yapıyı öğrenmesine katkı sağlamıştır. Veri seti, zaman serisi analizlerine uygun olacak şekilde kronolojik sıraya göre eğitim ve test kümelerine ayrılmıştır. Bu kapsamda, 2010–2017 yılları arası gözlemler eğitim seti, 2018–2020 yılları arası gözlemler ise test seti olarak ayrılmıştır. Bu ayrım sayesinde model geçmiş dönem verileri kullanılarak eğitilmiş ve örneklem dışı (out-of-sample) gözlemler üzerinde test edilmiştir. Böylece modelin yalnızca veri setine uyum başarısı değil, aynı zamanda farklı dönemler üzerindeki genelleme performansı da değerlendirilmiştir.

Modelleme sürecinde hem doğrusal hem de doğrusal olmayan yöntemler kullanılmıştır. Öncelikle karşılaştırma amacıyla doğrusal regresyon modelleri kurulmuş, ardından ana model

olarak Rassal Orman regresyonu regresyon yöntemi uygulanmıştır. Rassal Orman regresyonu modeli kurulurken, her bir ağaçta bölünme için kullanılacak değişken sayısını ifade eden mtry parametresi sabit tutulmuş ve model performansının ağaç sayısının duyarlılığını incelemek amacıyla farklı ntree değerleri (100,500 ve 1000) kullanılmıştır.

4.3. Model Sonuçları

4.3.1. Doğrusal Regresyon (EKK-OLS) Modeli Sonuçları

Rassal Orman regresyonu modelinden elde edilen bulguların karşılaştırmalı olarak değerlendirilebilmesi amacıyla üç farklı doğrusal regresyon modeli tahmin edilmiştir. Modeller, zamansal etkileri ve ülkeler arası yapısal farklılıkları farklı biçimlerde dikkate alacak şekilde kurgulanmıştır. Model 1'de cari ve gecikmeli bağımsız değişkenler ile yıllara ait kukla değişkenler kullanılmıştır. Model 2'de bunlara ek olarak her bir ülkenin etkisi de ayrı kukla değişkenler olarak dahil edilmiştir. Model 3 ise yıl kuklaları yerine doğrusal zaman trendi kullanılarak oluşturulmuş ve bu sayede eğitim ve test performanslarının birlikte değerlendirilmesine imkan sağlanmıştır.

Tablo 3: Doğrusal Regresyon Model 1 Sonuçları

Değişken	Katsayı	Std. Hata	t-istatistiği	p-değeri
Sabit	0.964	0.079	12.269	0.001*
CO_2	1.297	0.587	2.210	0.030**
GSYH	-0.111	0.385	-0.289	0.773
CSH	1.590	0.919	1.730	0.088***
KN	-6.640	2.947	-2.253	0.027*
HK	-0.135	0.417	-0.325	0.746
$CO_{2(t-1)}$	-1.333	0.583	-2.285	0.025**
$GSYH_{t-1}$	0.011	0.380	0.028	0.978
CSH_{t-1}	-2.414	0.947	-2.550	0.013*
KN_{t-1}	6.592	2.917	2.260	0.027**
HK_{t-1}	0.152	0.400	0.381	0.704
D_{2011}	0.134	0.055	2.441	0.017*
D_{2012}	0.090	0.059	1.536	0.129
D_{2013}	0.117	0.050	2.348	0.021**
D_{2014}	0.185	0.055	3.349	0.001*
D_{2015}	0.129	0.060	2.160	0.034**
D_{2016}	0.171	0.056	3.051	0.003*
D_{2017}	0.193	0.052	3.718	0.001*

Not: *,**,*** sırasıyla %1, %5, %10 anlamlılık düzeylerini göstermektedir.

Model 1, zaman etkilerini kontrol edebilmektedir ancak ülkeler arası yapısal farklılıkları içermemektedir. Zaman etkilerini kontrol edebilmek amacıyla yalnızca eğitim veri seti kapsamında modele kukla değişkenler ilave edilmiştir. Bu kapsamda, eğitim setinin başlangıç yılı olan 2010 yılı referans kategori olarak belirlenmiş ve diğer yıllar (2011-2017) bu referans yıl ile karşılaştırmalı olarak modele dahil edilmiştir. Sonuçlar, modelin açıklama gücünün orta düzeyde kaldığını göstermektedir. Bu modelde CO_2 değişkeni cari dönemde pozitif ve anlamlı iken $CO_{2(t-1)}$ negatif ve anlamlıdır. Benzer biçimde KN cari dönemde negatif ve anlamlı, KN_{t-1} ise pozitif ve anlamlı bulunmuştur. CSH değişkeni yalnızca %10 anlamlılık düzeyinde pozitif etki gösterirken, CSH_{t-1} negatif ve anlamlıdır.

Cari ve gecikmeli değişkenlerin bazı durumlarda ters işaretli çıkması, zaman etkisi ile birlikte değerlendirildiğinde, ilişkilerin doğrusal yapıda istikrarlı olmadığını ve ülke heterojenliğinin katsayıları etkileyebileceğini düşündürmektedir. Ayrıca yıllara ait kukla değişkenlerin önemli bir kısmının pozitif ve anlamlı olması, yaşam süresinin dönemler itibariyle genel olarak artış eğiliminde olduğunu göstermektedir. Bununla birlikte ülke etkileri modele dahil edilmediği için, bu modelin yaşam süresi üzerindeki yapısal farklılıkları tam olarak açıklayamadığı söylenebilir.

Tablo 4: Doğrusal Regresyon Model 2 Sonuçları

Değişken	Katsayı	Std. Hata	t-istatistiği	p-değeri
Sabit	0.566	0.315	1.796	0.077***
CO_2	0.085	0.204	0.418	0.677
GSYH	-0.361	0.130	-2.767	0.007*
CSH	0.044	0.376	0.118	0.906
KN	3.970	3.222	1.232	0.222
HK	-0.075	0.150	-0.502	0.617
$CO_{2(t-1)}$	-0.181	0.211	-0.859	0.393
$GSYH_{t-1}$	-0.103	0.142	-0.729	0.468
CSH_{t-1}	-0.654	0.376	-1.742	0.086***
KN_{t-1}	-3.357	3.075	-1.092	0.279
HK_{t-1}	-0.087	0.149	-0.585	0.561
D_{2011}	0.085	0.018	4.707	0.001*
D_{2012}	0.075	0.020	3.724	0.001*
D_{2013}	0.089	0.022	4.110	0.001*
D_{2014}	0.147	0.027	5.415	0.001*
D_{2015}	0.087	0.030	2.937	0.005*
D_{2016}	0.105	0.031	3.398	0.001*
D_{2017}	0.117	0.034	3.397	0.001*
$D_{Belçika}$	-0.189	0.192	-0.985	0.328
$D_{Bileşik\ Krallık}$	-0.020	0.109	-0.179	0.858

Tablo 4. devam

$D_{Danimarka}$	-0.099	0.110	-0.897	0.373
D_{Fransa}	0.278	0.108	2.579	0.012*
$D_{Hollanda}$	-0.010	0.140	-0.072	0.943
D_{Kanada}	0.185	0.098	1.883	0.064***
$D_{Lüksemburg}$	0.168	0.176	0.952	0.344
$D_{Norveç}$	0.280	0.095	2.959	0.004*
$D_{Portekiz}$	0.086	0.247	0.348	0.729
$D_{İtalya}$	0.425	0.216	1.970	0.053***
$D_{İzlanda}$	-0.022	0.146	-0.152	0.879

Not: *,**,*** sırasıyla %1, %5, %10 anlamlılık düzeylerini göstermektedir.

Model 2'de Amerika referans kategori olarak dışarıda bırakılmış ve diğer ülke katsayıları bu ülkeye göre yorumlanmıştır. Sonuçlara göre, R^2 değeri 0.972'ye yükselmiştir. Bu, ülkeler arası yapısal farklılıkların yaşam süresi üzerinde son derece güçlü bir belirleyici olduğunu göstermiştir. Bu modelde önceki modele göre birçok cari ve gecikmeli değişkenin anlamlılığını kaybettiği görülmektedir. Bu durum, ülke etkileri modele dahil edilmediğinde bazı değişkenlerin aslında ülkeler arası farklılıkları dolaylı biçimde yansıtmış olabileceğini düşündürmektedir.

Zaman etkilerinin tamanına yakını hâlâ pozitif ve anlamlıdır. Ülke etkileri incelendiğinde ise Fransa ve Norveç değişkenlerinin pozitif ve anlamlı olduğu, Kanada ve İtalya değişkenlerinin ise %10 düzeyinde anlamlılık sergilediği görülmektedir.

Tablo 5: Doğrusal Regresyon Model 3 Sonuçları

Değişken	Katsayı	Std. Hata	t-istatistiği	p-değeri
Sabit	-17.688	10.910	-1.621	0.109
CO_2	-0.399	0.215	-1.861	0.067***
GSYH	-0.170	0.122	-1.392	0.168
CSH	0.092	0.432	0.212	0.832
KN	4.026	3.774	1.067	0.290
HK	-0.170	0.123	-1.381	0.172
$CO_{2(t-1)}$	0.374	0.221	1.695	0.094***
$GSYH_{t-1}$	-0.110	0.124	-0.888	0.377
CSH_{t-1}	-0.714	0.433	-1.649	0.104
KN_{t-1}	-3.097	3.608	-0.858	0.394
HK_{t-1}	-0.077	0.136	-0.567	0.572
$D_{Yıl}$	0.009	0.006	1.629	0.108
$D_{Belçika}$	-0.254	0.225	-1.128	0.263
$D_{Bileşik\ Krallık}$	0.040	0.127	0.315	0.754

Tablo 5. devam

$D_{Danimarka}$	-0.114	0.129	-0.884	0.379
D_{Fransa}	0.382	0.124	3.082	0.003*
$D_{Hollanda}$	-0.015	0.162	-0.093	0.927
D_{Kanada}	0.192	0.116	1.652	0.103
$D_{Lüksemburg}$	-0.023	0.204	-0.115	0.909
$D_{Norveç}$	0.248	0.111	2.230	0.029**
$D_{Portekiz}$	0.356	0.290	1.229	0.223
$D_{İtalya}$	0.647	0.248	2.615	0.011*
$D_{İzlanda}$	-0.124	0.174	-0.711	0.479

Not: *,**,*** sırasıyla %1, %5, %10 anlamlılık düzeylerini göstermektedir.

Model 3, çalışmada temel açıklayıcı modeller olan Model 1 ve Model 2'ye alternatif bir spesifikasyon olarak, tahmin performansının değerlendirilmesi amacıyla oluşturulmuştur. Bu modelde, yıl kukla değişkenleri yerine zaman trendini temsil eden sayısal yıl değişkeni kullanılmıştır. Bu tercih, modelin yalnızca mevcut veriyi açıklamakla sınırlı kalmayıp, aynı zamanda örneklem dışındaki dönemler için tahmin üretme kapasitesini de sağlamaktadır. Bu çalışmada eğitim veri seti 2010–2017 dönemini kapsamakta olup, model performansı 2018–2020 dönemine ait örneklem dışı gözlemler üzerinden değerlendirilmiştir. Bu yaklaşım, modelin daha önce görmediği dönemler üzerindeki tahmin başarısını test etmeye olanak sağlamaktadır.

Dolayısıyla, doğrusal modelin genelleme performansını değerlendirmek ve olası aşırı öğrenme (overfitting) sorununu test etmek amacıyla eğitim ve test veri setleri üzerinde karşılaştırmalı analiz gerçekleştirilmiştir. Elde edilen bulgular, modelin eğitim setinde yüksek bir açıklama gücüne (sahip olduğunu, ancak test setinde bu performansın görece düştüğünü (göstermektedir. Bu durum modelin belirli ölçüde aşırı öğrenme eğilimi taşıdığını ortaya koymaktadır.

Değişkenler arasındaki doğrusal olmayan ilişkileri ortaya çıkarmak amacıyla Rassal Orman regresyonu modeli uygulanmıştır. Model kapsamında farklı ağaç sayıları (ntree=100,500,1000) kullanılarak 3 farklı model tahmin edilmiş ve performansları karşılaştırılmıştır.

Tablo 6: Rassal Orman Regresyonu Modellerinin Performans Sonuçları

Model	Eğitim R^2	Test R^2	Eğitim RMSE	Test RMSE	Eğitim MAE	Test MAE	Eğitim MAPE (%)	Test MAPE (%)
RF (100)	0.976	0.802	0.0272	0.0922	0.0180	0.0722	3.23	8.60
RF (500)	0.982	0.808	0.0237	0.0907	0.0162	0.0703	2.90	8.43
RF (1000)	0.982	0.816	0.0238	0.0890	0.0164	0.0688	2.97	8.13

Tablo incelendiğinde, Rassal Orman regresyonu modellerinin hem eğitim hem test setinde oldukça yüksek performans sergilediği görülmektedir. Eğitim setinde R2 değerleri tüm modeller için %97'nin üstünde elde edilmiştir. Test setinde ise %80-82 aralığında olup, modelin güçlü bir genelleme performansı sunduğunu göstermektedir. Ağaç sayısının artırılmasıyla model performansında belirli bir iyileşme gözlenmiştir. Özellikle ntree=1000 olan model, test se-

tinde en yüksek R2 ve en düşük hata değerlerini üretmiştir. Bununla birlikte 500 ile 1000 ağaçlı modeller arasında performans farkının oldukça sınırlı olduğu görülmektedir. Bu durum, belirli bir eşik değerden sonra ağaç sayısını artırmanın marjinal katkısının azaldığını göstermektedir.

RMSE ve MAE değerleri incelendiğinde, model tahmin hatalarının düşük seviyede olduğu görülmektedir. Ayrıca MAPE değerlerinin test setinde %8 civarında olması, modelin farklı ölçeklerdeki veriler için de güvenilir tahminler üretebildiğini göstermektedir.

Rassal Orman regresyonu modellerinde eğitim ve test performansları karşılaştırıldığında, eğitim R2 değerlerinin test R2 değerlerinden daha yüksek olduğu görülmektedir. Ancak bu fark oldukça küçüktür. Bu durum, modelin eğitim verisini iyi öğrenmesine rağmen test verisine de başarılı şekilde genelleme yapabildiğini göstermektedir. Dolayısıyla Rassal Orman regresyonu modelinde belirgin bir aşırı öğrenme sorunu bulunmamaktadır.

Tablo 7: Doğrusal Regresyon ve Rassal Orman Regresyonu Modellerinin Karşılaştırması

Modeller	Eğitim R^2	Test R^2	RMSE (Test)	MAE (Test)	MAPE (Test, %)
Doğrusal Regresyon Model 1	0.653	-	-	-	-
Doğrusal Regresyon Model 2	0.972	-	-	-	-
Doğrusal Regresyon Model 3	0.955	0.699	-	-	-
Rassal Orman Regresyonu (100)	0.976	0.802	0.0922	0.0722	8.60
Rassal Orman Regresyonu (500)	0.982	0.808	0.0907	0.0703	8.43
Rassal Orman Regresyonu (1000)	0.982	0.816	0.0890	0.0688	8.13

Tablo incelendiğinde, Rassal Orman regresyonu modellerinin test setindeki performanslarının doğrusal modellere kıyasla daha yüksek olduğu görülmektedir. Özellikle en iyi performansı veren Rassal Orman regresyonu (ntree=1000) modelinde test R^2 değeri 0.816 iken, doğrusal modeller arasında test performansı değerlendirilebilen Model 3 için bu değer 0.699 olarak elde edilmiştir. Bu sonuç, Rassal Orman regresyonu modelinin veri içerisindeki karmaşık ve doğrusal olmayan ilişkileri daha başarılı şekilde yakalayabildiğini göstermektedir.

Doğrusal regresyon modelleri arasında en yüksek eğitim başarısı Model 2'de elde edilmiştir ($R^2 \approx 0.972$). Ancak bu modelin dış örneklem performansı ölçülemediği için genelleme gücü konusunda kesin bir değerlendirme yapmak mümkün değildir. Buna karşılık Model 3, hem eğitim hem test performansının birlikte değerlendirilebildiği tek doğrusal modeldir. Bu modelde test R^2 değerinin daha düşük kalması, doğrusal modelin genelleme performansının sınırlı olduğunu göstermektedir.

Modellerin aşırı öğrenme eğilimleri incelendiğinde, doğrusal regresyon ve Rassal Orman regresyonu arasında belirgin farklar olduğu görülmektedir. Model 3'te eğitim R^2 değeri 0.955, test R^2 değeri ise 0.699 olup, aradaki fark yaklaşık 0.26'dır. Bu durum, modelin eğitim verisini oldukça iyi öğrenmesine rağmen test verisine aynı başarıyla genelleyemediğini ve hafif-orta düzeyde aşırı öğrenme eğilimi bulunduğunu göstermektedir. Buna karşılık Rassal Orman regresyonu modelinde eğitim ve test R^2 değerleri arasındaki fark daha sınırlıdır. Örneğin RF (1000) modelinde eğitim R^2 değeri 0.982, test R^2 değeri ise 0.816 olup fark yaklaşık 0.17 seviyesindedir. Bu durum, Rassal Orman regresyonu modelinin daha dengeli bir öğrenme sürecine sahip ol-

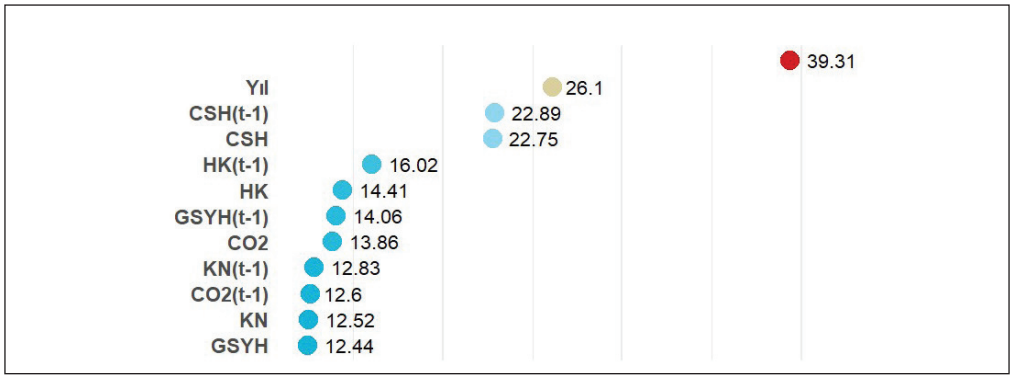
duğunu ve aşırı öğrenme riskinin doğrusal modele kıyasla daha düşük olduğunu göstermektedir.

Doğrusal ve doğrusal olmayan modeller arasındaki fark yalnızca performans metrikleriyle sınırlı değildir. Doğrusal regresyon modelleri, değişkenlerin bağımlı değişken üzerindeki etkilerini doğrudan katsayılar aracılığıyla yorumlama imkanı sunmaktadır. Bu nedenle ekonomik ve teorik yorumlar açısından önemli bir avantaj sağlamaktadır. Ancak katsayıların model spesifikasyonuna bağlı olarak işaret ve anlamlılık değiştirmesi, doğrusal modelin veri yapısını tam olarak yansıtamayabileceğini göstermektedir.

Rassal Orman regresyonu modeli ise doğrusal olmayan ilişkileri ve değişkenler arasındaki karmaşık etkileşimleri modelleyebilme kapasitesine sahiptir. Bu nedenle tahmin performansı daha yüksektir. Ancak bu model doğrudan katsayı üretmediği için klasik anlamda yorum yapma imkanı sınırlıdır. Bu eksiklik, değişken önem analizleri ve kısmi bağımlılık grafikleri ile giderilmeye çalışılmıştır.

Rassal Orman regresyonu modelinde değişkenlerin bağımlı değişken üzerindeki göreli önemini belirlemek amacıyla değişken önem analizleri gerçekleştirilmiştir. Aşağıda en iyi performansı veren model için elde edilen önem düzeyleri sunulmaktadır. Bu sonuçlar, değişkenlerin model performansına katkısını ölçen %IncMSE (Permutation Importance) kriterine dayanmaktadır.

Şekil 2: Rassal Orman Regresyonu Değişken Önem Düzeyleri



Değişken önem düzeyleri incelendiğinde, yıl (zaman) değişkeninin açık ara en yüksek önem düzeyine sahip olduğu görülmektedir. Bu bulgu, yaşam süresinin zaman içerisinde sistematik bir artış eğilimi gösterdiğini ve zamansal dinamiklerin model açısından belirleyici bir rol oynadığını ortaya koymaktadır. Bu sonuç, doğrusal modellerde yer alan zaman etkileri ile de uyumlu bir yapı sergilemektedir.

Zaman değişkenini takiben, sağlık harcamalarının gecikmeli değeri (CSHt-1) ve cari değeri (CSH) modelde en önemli değişkenler arasında yer almaktadır. Bu durum, sağlık harcamalarının yaşam süresi üzerindeki etkisinin yalnızca cari dönemde değil, aynı zamanda zaman içerisinde gecikmeli olarak ortaya çıktığını göstermektedir. Dolayısıyla sağlık politikalarının etkisinin dinamik bir yapı sergilediği ve kısa vadeden ziyade kademeli olarak hissedildiği anlaşılmaktadır.

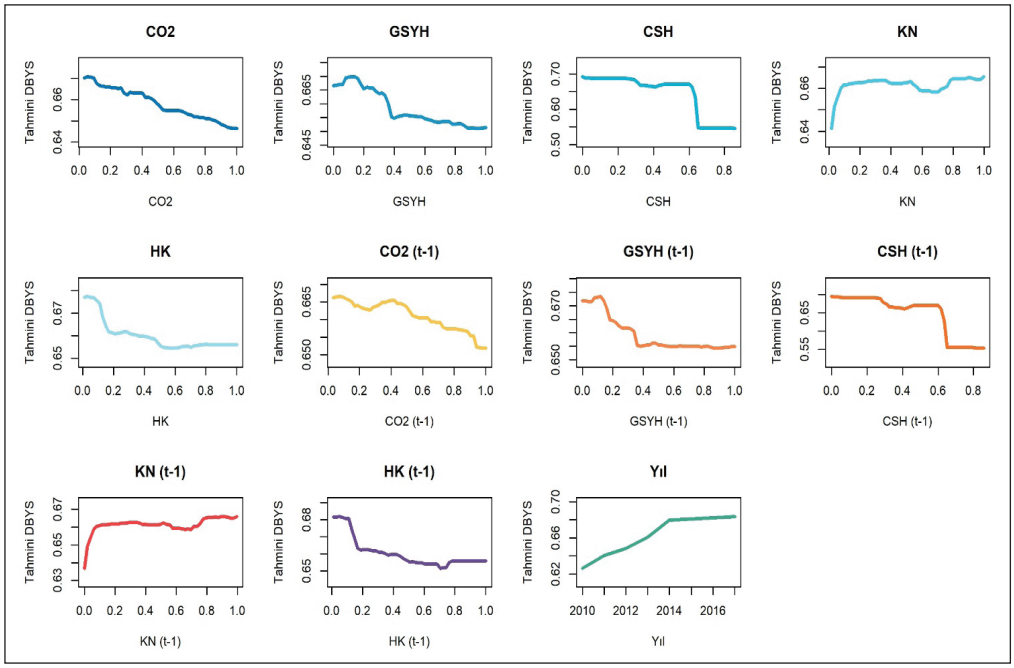
Bununla birlikte, hava kirliliği (HK) ve gecikmeli değeri, kişi başına gelir (GSYH) ve diğer değişkenlerin orta düzeyde önem taşıdığı; buna karşılık bazı ekonomik ve çevresel değişkenlerin görece daha düşük önem düzeylerine sahip olduğu görülmektedir. Özellikle GSYH değişkeninin düşük önem düzeyi, bu değişkenin etkisinin doğrudan olmaktan ziyade sağlık harcamaları gibi ara kanallar üzerinden dolaylı biçimde ortaya çıkabileceğine işaret etmektedir.

Değişken önem düzeyleri ile doğrusal regresyon modellerinin sonuçları birlikte değerlendirildiğinde dikkat çekici farklılıklar ortaya çıkmaktadır. Doğrusal Regresyon modellerinde bazı değişkenlerin katsayıları istatistiksel olarak zayıf veya anlamsız bulunmasına rağmen, Rassal Orman regresyonu modelinde aynı değişkenlerin yüksek önem düzeyine sahip olması, ilişkilerin doğrusal bir yapıdan sapma gösterdiğini ortaya koymaktadır. Özellikle sağlık harcamalarının doğrusal modellerde sınırlı biçimde yakalanan etkisinin, doğrusal olmayan model çerçevesinde daha belirgin hâle geldiği görülmektedir.

Genel olarak değerlendirildiğinde, elde edilen bulgular yaşam süresini belirleyen faktörlerin yalnızca doğrusal etkilerle sınırlı olmadığını; zamansal, gecikmeli ve etkileşimli bir yapı sergilediğini ortaya koymaktadır. Bu durum, doğrusal ve doğrusal olmayan yöntemlerin birlikte kullanılmasının, değişkenler arasındaki ilişkilerin daha kapsamlı ve gerçekçi biçimde analiz edilmesine olanak sağladığını göstermektedir.

Rassal Orman regresyonu modelinin değişkenler arasındaki doğrusal olmayan ilişkileri ortaya koyma kapasitesini daha detaylı incelemek amacıyla kısmi bağımlılık (Partial Dependence) grafikleri analiz edilmiştir. Bu grafikler, her bir bağımsız değişkenin diğer değişkenler sabit tutulduğunda bağımlı değişken üzerindeki marjinal etkisini göstermektedir.

Şekil 3: Kısmi Bağımlılık Grafikleri



Şekil 3'te sunulan kısmi bağımlılık grafikleri incelendiğinde, değişkenler ile DBYS arasındaki ilişkilerin büyük ölçüde doğrusal olmadığı ve belirli eşik değerler içerdiği görülmektedir.

CO_2 değişkeni için elde edilen bulgular, değişkenin artışıyla birlikte DBYS üzerinde genel olarak azalan bir etki olduğunu göstermektedir. Buna karşılık GSYH değişkeni, düşük seviyelerde sınırlı bir pozitif etki gösterirken belirli bir eşikten sonra negatif bir eğilim sergilemektedir. Bu durum, gelir düzeyinin yaşam süresi üzerindeki etkisinin doğrusal olmadığını ve belirli bir noktadan sonra azalan getiri özelliği taşıdığını ortaya koymaktadır.

CSH değişkeninde ise belirli bir eşik seviyesine kadar etkilerin sınırlı olduğu, ancak bu seviyeden sonra daha keskin bir değişim gözlendiği dikkat çekmektedir. Benzer şekilde gecikmeli değişkenlerde de eşik etkileri ve doğrusal olmayan yapılar gözlemlenmektedir. Özellikle CSHt-1 değişkeninde belirli bir noktadan sonra ani düşüş, gecikmeli etkilerin belirli seviyelerde daha güçlü hâle geldiğini göstermektedir.

KN ve HK değişkenlerinde ise düşük seviyelerde daha güçlü etkiler gözlenirken, belirli bir seviyeden sonra etkinin yataylaştığı görülmektedir. Bu durum, bazı değişkenlerin yalnızca belirli aralıklarda etkili olduğunu ve doygunluk (saturation) etkisi oluşturduğunu göstermektedir. CSH değişkeninin hem cari hem de gecikmeli etkilerinin güçlü olması, sağlık yatırımlarının kısa vadede sınırlı, ancak orta ve uzun vadede daha belirgin etkiler yarattığını göstermektedir. Bu durum, sağlık politikalarının sürekliliğinin önemini ortaya koymaktadır. Zaman değişkeninin yüksek önem düzeyi ise yaşam süresinin yalnızca ekonomik faktörlerle değil, aynı zamanda teknolojik gelişmeler, tıbbi ilerlemeler ve genel yaşam standartlarındaki iyileşmelerle de yakından ilişkili olduğunu göstermektedir.

Zaman değişkenine ilişkin grafik ise DBYS'nin yıllar itibarıyla genel olarak artan bir eğilim sergilediğini ortaya koymaktadır. Ancak bu artışın doğrusal olmadığı ve bazı dönemlerde daha belirgin hâle geldiği görülmektedir.

Genel olarak değerlendirildiğinde, kısmi bağımlılık grafikleri değişkenler ile DBYS arasındaki ilişkilerin önemli ölçüde doğrusal olmayan yapılar içerdiğini göstermektedir. Bu bulgular, doğrusal regresyon modellerinde bazı katsayıların tutarsız veya anlamsız çıkmasının temel nedenlerinden birinin modelin doğrusal varsayımı olduğunu ortaya koymaktadır. Dolayısıyla Rassal Orman regresyonu modeli, bu tür karmaşık ilişkileri daha başarılı bir şekilde yakalayarak analizin açıklayıcılığını artırmaktadır.

Bu bölümde elde edilen bulgular, doğrusal ve doğrusal olmayan model sonuçlarının birlikte değerlendirilmesinin önemini ortaya koymaktadır. Çalışmada her iki model yaklaşımının birlikte kullanılması, hem tahmin doğruluğunu artırmakta hem de değişkenlerin ekonomik etkilerinin daha kapsamlı biçimde yorumlanmasına imkan sağlamaktadır. Ayrıca elde edilen bulgular birlikte değerlendirildiğinde, yaşam süresi üzerinde hem zamansal hem de yapısal faktörlerin belirleyici olduğu görülmektedir. Özellikle ülkeler arası farklılıkların yüksek önem düzeyine sahip olması, sağlık sistemleri, sosyal politikalar ve kurumsal yapıların yaşam süresi üzerinde önemli rol oynadığını göstermektedir.

5. Sonuç

Bu çalışmada, doğumda beklenen yaşam süresi (DBYS) üzerinde etkili olan ekonomik, çevresel ve sosyal faktörler, doğrusal regresyon modelleri ve doğrusal olmayan bir makine öğrenmesi yöntemi olan Rassal Orman regresyonu yaklaşımı ile analiz edilmiştir. Elde edilen bulgular, doğrusal ve doğrusal olmayan yöntemlerin birlikte kullanımının hem tahmin perfor-

mansını artırdığını hem de değişkenler arasındaki ilişkilerin daha kapsamlı ve gerçekçi biçimde anlaşılmasına katkı sağladığını göstermektedir.

Doğrusal modeller incelendiğinde, ülkelere ait kukla değişkenlerin modele dahil edilmesiyle açıklama gücünün önemli ölçüde arttığı görülmektedir. Özellikle Model 2'de elde edilen yüksek R^2 değeri, ülkeler arası yapısal farklılıkların yaşam süresi üzerinde belirleyici rol oynadığını göstermektedir. Bu bulgu, sağlık sistemleri, kurumsal yapı ve sosyal politikalar gibi ülkeye özgü faktörlerin önemini vurgulamaktadır. Bununla birlikte, doğrusal modellerin genelleme kabiliyetinin sınırlı olması, bu modellerin tahmin performansının dikkatli değerlendirilmesi gerektiğine işaret etmektedir.

Rassal Orman regresyonu modelleri ise hem eğitim hem test veri setlerinde yüksek performans sergilemiş ve doğrusal modellere kıyasla daha güçlü bir genelleme kabiliyeti sunmuştur. Özellikle 1000 ağaçlı modelin en yüksek test R^2 değerine ve en düşük hata metriklerine sahip olması, doğrusal olmayan yöntemlerin bu tür veri yapılarında daha başarılı sonuçlar üretebildiğini göstermektedir. Ayrıca aşırı öğrenme açısından değerlendirildiğinde, Rassal Orman regresyonu modelinin doğrusal modellere kıyasla daha dengeli bir yapı sergilediği tespit edilmiştir.

Değişken önem analizleri, zaman değişkeninin en belirleyici faktör olduğunu, bunu sağlık harcamalarının cari ve gecikmeli değerlerinin izlediğini ortaya koymaktadır. Bu bulgular, yaşam süresinin zaman içerisinde sistematik bir değişim gösterdiğini ve sağlık politikalarının etkilerinin gecikmeli ve kademeli olarak ortaya çıktığını göstermektedir. Kısmi bağımlılık grafikleri de bu ilişkilerin doğrusal olmayan bir yapı sergilediğini ve özellikle sağlık harcamalarında azalan marjinal etkilerin söz konusu olabileceğini desteklemektedir.

Diğer değişkenler açısından değerlendirildiğinde, GSYH değişkeninin görece düşük önem düzeyine sahip olması, ekonomik refahın yaşam süresi üzerindeki etkisinin doğrudan olmaktan ziyade sağlık harcamaları gibi ara kanallar üzerinden dolaylı olarak ortaya çıkabileceğine işaret etmektedir. Benzer şekilde, KN değişkeninin doğrusal analizlerde zayıf görünmesine rağmen model içerisinde belirli bir önem düzeyine sahip olması, bu değişkenin etkisinin doğrusal olmayan yapılar ve diğer değişkenlerle etkileşimler yoluyla ortaya çıkabileceğini düşündürmektedir.

Çevresel değişkenler incelendiğinde, CO_2 emisyonlarının görece düşük önem düzeyi, bu değişkenin etkisinin kısa dönemde değil uzun vadede ve birikimli olarak ortaya çıkmasıyla açıklanabilir. HK değişkeninin ise orta düzeyde bir etkiye sahip olması, çevresel faktörlerin yaşam süresi üzerindeki etkisinin doğrudan ancak sınırlı bir çerçevede gerçekleştiğini göstermektedir. Bu durum, çevresel etkilerin ülke yapısı, sağlık altyapısı ve politika düzeyi gibi faktörlere bağlı olarak farklılaşabileceğine işaret etmektedir.

Elde edilen bulgular literatürde yer alan çalışmalarla önemli ölçüde örtüşmektedir. Öncelikle, sağlık harcamalarının yaşam süresi üzerindeki belirleyici rolü bu çalışmada da açık biçimde ortaya konulmuştur. Rassal Orman regresyonu modeli ile elde edilen bu sonuçlar Tüylüoğlu & Tekin (2009), Linden & Ray (2017), Jaba vd. (2014), Aydın (2020) ve Akbal (2021) tarafından elde edilen bulgularla paralellik göstermektedir. Bu çalışmaların ortak sonucu, sağlık harcamalarının yaşam süresi üzerindeki etkisinin gelir düzeyine kıyasla daha güçlü olabileceği yönündedir.

Ülkeler arası yapısal farklılıkların belirleyici rolü de literatürle örtüşen bir diğer önemli bulgudur. Doğrusal regresyon modelinde ülkelere ait kukla değişkenlerin modele dahil edilme-

siyle açıklama gücünün önemli ölçüde artması, Jaba vd. (2014)'ün çalışmasında vurgulanan ülke etkilerinin anlamlılığı ile doğrudan örtüşmektedir.

Bu çalışmada CO_2 emisyonlarının düşük önem düzeyine sahip olması, Börüban & Özgür Güler (2022) ve Tıraş & Özbek (2020) çalışmalarında elde edilen anlamsız etki bulgularıyla paralellik göstermektedir. Ekonomik ve sosyal değişkenler açısından elde edilen bulgular da literatürle tutarlı bir heterojen yapı ortaya koymaktadır. Özellikle kentleşme ve gelir değişkenlerinin etkilerinin doğrusal modellerde farklı sonuçlar üretmesi, Panahi & Aleemran (2016) ve Tıraş & Özbek (2020) çalışmalarında elde edilen bulgularla örtüşmektedir. Bu durum, söz konusu değişkenlerin yaşam süresi üzerindeki etkilerinin doğrudan değil, diğer değişkenlerle etkileşim içinde ortaya çıkabileceğini düşündürmektedir. Sonuç olarak, bu çalışmada elde edilen bulgular hem değişkenler arasındaki ilişkilere hem de kullanılan yöntemlerin performansına ilişkin olarak literatürdeki mevcut bulgularla büyük ölçüde örtüşmektedir.

Araştırma ve Yayın Etiği Beyanı

Bu çalışma, bilimsel araştırma ve yayın etiği kurallarına uygun olarak hazırlanmıştır. Herhangi bir etik ihlal veya intihal durumu söz konusu değildir.

Araştırmacıların Katkı Oranı Beyanı

İlk yazarın katkısı % 70, ikinci yazarın katkısı % 30 düzeyindedir.

Çatışma Beyanı

Makalenin yazarları arasında çıkar çatışması bulunmamaktadır.

Kaynakça

Akbal, F. (2021). Türkiye'de cari sağlık harcaması, ekonomik büyüme ve doğumda beklenen yaşam süresinin ARDL sınır testi ile analizi. *Medeniyet Araştırmaları Dergisi, 6*(1), 179-203. https://doi.org/10.52539/mad.880739.

Aydın, B. (2020). The impact of economic indicators on life expectancy: A panel data analysis. İstanbul İktisat *Dergisi - Istanbul Journal of Economics, 70*(1), 163-181. https://doi.org/10.26560/istjecon.761472.

Bergstra, J., & Bengio, Y. (2012). Random search for hyper-parameter optimization. *Journal of Machine Learning Research*, 13, 281–305

Breiman, L. (2001). Random Forests. *Machine Learning*, *45*(1), 5-32.

Börüban, C., & Özgür Güler, E. (2022). Sağlık sistemi belirleyicileri ve göstergeleri üzerine bir yol analizi çalışması. *Dokuz Eylül Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 24*(4), 1602-1629. https://doi.org/10.16953/deusosbil.1181556.

Çakır, N. Z. (2023). E-7 ülkelerinde doğumda beklenen yaşam süresi ile karbondioksit emisyonu arasındaki ilişkinin panel nedensellik analizi. *19 Mayıs Sosyal Bilimler Dergisi, 4*(3), 102-111. https://doi.org/10.52835/19maysbd.1336133.

Demirezen, S. (2021). ARIMA ve rassal orman yöntemi ile altın fiyatlarının öngörülmesi ve tahmin performanslarının karşılaştırılması. *Social Sciences Research Journal*, *10*(3), 747-758.

Demirezen, S., & Çetin, M. (2021). Rassal orman regresyonu ve destek vektör regresyonu ile piyasa takas fiyatının tahmini. *Nicel Bilimler Dergisi 3*(1), 1-15.

Doğan, S., Büyükkör, Y., & Özdemir Güler, Z. (2022). Destek vektör ve rassal orman regresyonu ile borsa endeks değerlerinin tahmini. İçinde Ö. İpek (Ed.), *İktisat ve finansta makine öğrenmesi* (s. 41–59). Ankara: Gazi Kitabevi.

Dondurmacı, G. A., & Çınar, A. (2014). Finans sektöründe veri madenciliği uygulaması. *Akademik Sosyal Araştırmalar Dergisi*, 258-271.

Goklany, I. M. (2012). Is climate change the number one threat to humanity? *Wiley Interdisciplinary Reviews: Climate Change*, 489-508.

Gökçek, Ö. B., Şaşa, N., Dokuz, Y., & Bozdağ, A. (2022). PM10 parametresinin makine öğrenmesi algoritmalari ile mekânsal analizi, Kayseri İli Örneği . *Dokuz Eylül Üniversitesi Mühendislik Fakültesi Fen ve Mühendislik Dergisi*, 65-80.

Hastie, T., Tibshirani, R., & Friedman, J. (2009). *The elements of statistical learning*. Springer.

Jaba, E., Balan, C. B., & Robu, I.-B. (2014). The relationship between life expectancy at birth and health expenditures estimated by a cross-country and time-series analysis. *Procedia Economics and Finance*, 108-114.

Karasu, S., Altan, A., Saraç, Z., & Hacıoğlu, R. (2018). Prediction of bitcoin prices with machine learning methods using time series data. In 2018 26th Signal Processing and Communications Applications Conference (SIU) (pp. 1–4). IEEE. https://doi.org/10.1109/SIU.2018.8404760

Khaidem, L., Saha, S., & Roy Dey, S. (2016). Predicting the direction of stock market prices using random forest. *arXiv preprint arXiv:1605.00003*.

Koç Ustalı, N., Tosun, N., & Tosun, Ö. (2021). Makine öğrenmesi teknikleri ile hisse senedi fiyat tahmini. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 1-16.

Kohavi, R. (1995). A study of cross-validation and bootstrap for accuracy estimation and model selection. In C. S. Mellish (Ed.), Proceedings of the 14th International Joint Conference on Artificial Intelligence (IJCAI) (Vol. 2, pp. 1137–1145). San Francisco, CA: Morgan Kaufmann Publishers.

Liaw, A., & Wiener, M. (2002). Classification and regression by randomForest. R News, 2(3), 18-22.

Linden, M., & Ray, D. (2017). Life expectancy effects of public and private health expenditures in OECD countries 1970–2012: Panel time series approach. *Economic Analysis and Policy*, 1-25.

Newhouse, J. P. (1992). Medical care costs: How much welfare loss? *Journal of Economic Perspectives, 6*(3), 3-21. https://doi.org/10.1257/jep.6.3.3

Özkan, B., Parim, C., & Çene, E. (2023). Ülkelerin gelişmişlik düzeylerinin karar ağacı ve rastgele orman yöntemleriyle tahmin edilmesi. *EKOIST Journal of Econometrics and Statistics*, 87-104. https://doi.org/10.26650/ekoist.2023.38.1172190.

Panahi, H., & Aleemran, S. A. (2016). The Effect of inflation, health expenditure and urbanization on life expectancy in the Middle East and North Africa Countries (MENA). *Payesh*, *15*(4), 346-351.

Pope, C. A., & Dockery, D. W. (2006). Health effects of fine particulate air pollution: Lines that connect. *Journal of the Air & Waste Management Association, 56*(6), 709-742. https://www.tandfonline.com/doi/pdf/10.1080/10473289.2006.10464485

Rjoub, H., Odugbesan, J. A., Adebayo, T. S., & Wong, W.-K. (2021). Investigating the causal relationships among carbon emissions, economic growth, and life expectancy in Turkey: Evidence from time and frequency domain causality techniques. *Sustainability*, 2924. https://doi.org/10.3390/su13052924.

Scornet, E. (2018). Tuning parameters in random forests. *ESAIM: Proceedings and Surveys*, 144-162.

Tıraş, H. H., & Özbek, S. (2020). OECD ülkelerinde doğumda yaşam beklentisinin belirleyicilerinin ekonometrik analizi. *BMIJ, 8*(3), 2893–2923. http://dx.doi.org/10.15295/bmij.v8i3.1542

Tüylüoğlu, Ş., & Tekin, M. (2009). Gelir düzeyi ve sağlık harcamalarının beklenen yaşam süresi ve bebek ölüm oranı üzerindeki etkileri. Çukurova Üniversitesi İktisadi *ve İdari Bilimler Fakültesi Dergisi, 13*(1), 1-31.