

İŞSİZLİK ORANI ÖNGÖRÜLERİNDE MAKİNE ÖĞRENİMİ YAKLAŞIMLARI: TÜRKİYE ÜZERİNE BİR UYGULAMA

Polad ALİYEVⁱ 

Öz

İşsizlik, sadece kapsamlı bir ekonomik sorun değil, aynı zamanda tüm ulusların odak noktası haline gelen karmaşık bir sosyal sorundur. İşsizlik sorununun doğru bir şekilde ele alınması, ülkenin kalkınmasıyla doğrudan ilişkilidir. Bu yönde oluşturulan politikaların başarısı, işsizlik oranının doğru bir şekilde tahmin edilmesine dayanır. Bu makale, işsizlik oranı tahmininin yapılmasında yapay zekâ, makine öğrenimi ve klasik yöntemlerin kıyaslamasını amaçlamaktadır. Bu amaçla, Türkiye İstatistik Kurumu'ndan (TÜİK) Ocak 2005 verileriyle Aralık 2023 dönemini kapsayan işsizlik oranı verileri elde edilmiştir. Araştırmada ölçüt modeli olarak ARIMA, SARIMA modelleri, makine öğrenimi modelleri olarak Rassal Orman, XGBoost, LSTM ve GRU modelleri uygulanmıştır. Elde edilen sonuçlar, SARIMA'nın tahmin grafiğinin ve performans göstergelerinin ARIMA modeli performans değerlerinden daha iyi olduğunu göstermektedir. Makine öğrenimi modellerinde, MAPE dışındaki tüm hata ölçütleri SARIMA modelinin hata ölçütlerinden daha yüksektir. Ayrıca, bu modellerin belirleme katsayısı (R^2) da SARIMA modelinin belirleme katsayısından (R^2) daha büyüktür. Elde edilen sonuçlar en uygun metrik göstergeleri sergileyen makine öğrenimi yönteminin GRU modeli olduğunu ortaya koymuştur. Bu modelin MAE (Hataların Mutlak Değerlerinin Ortalaması) ve RMSE (Hata Kareler Ortalamasının Karekökü) değerleri en düşükken, R^2 ise en yüksektir. Buna en yakın göstergeleri Rassal Orman modeli sergilemektedir.

Anahtar Sözcükler yapay zekâ, işsizlik oranı, GRU, LSTM, tek değişkenli zaman serisi modelleri

MACHINE LEARNING APPROACHES IN UNEMPLOYMENT RATE PREDICTION: AN APPLICATION ON TÜRKİYE

Abstract

Unemployment is a complex economic and social issue affecting nations' development. Accurate unemployment rate estimation is crucial for successful policies aimed at addressing this issue. In this context, this article aims to compare artificial intelligence, machine learning, and classical methods of unemployment rate estimation. For this purpose, unemployment rate data covering the period between January 2005 and December 2023 were obtained from the Turkish Statistical Institute (TUIK). ARIMA and SARIMA models were applied as benchmark models, and Random Forest, XGBoost, LSTM, and GRU models were applied as machine learning models. The results show that the prediction graph and performance indicators of SARIMA are better than the ARIMA model performance values. In the machine learning models used in this study, all error measures except MAPE were higher than the error measures of the SARIMA model. Also, the coefficient of determination (R^2) of these models was larger than that of the coefficient of determination of the SARIMA model. Furthermore, the results revealed that the machine learning method that exhibits the most favorable metric indicators is the GRU model. This model's MAE (Mean Absolute Value of Errors) and RMSE (Root Mean Square Error Squared) values were the lowest, while R^2 was the highest. The Random Forest model exhibited the closest indicators.

Keywords artificial intelligence, unemployment rate, GRU, LSTM, univariate time series models

JEL Codes J01, C53, J60

Araştırma ve Yayın Etiği Beyanı Çalışma, araştırma ve yayın etiğinin gerektirdiği kurallar gözetilerek hazırlanmıştır. Etik kurul onayını gerektiren bir durum içermemektedir.

Finansal Destek ve Çıkar Beyanı Makalenin yazarı, herhangi bir çıkar çatışmasının olmadığını beyan eder. Çalışmada herhangi bir kurum ya da kuruluştan destek alınmamıştır.

GİRİŞ

İşsizlik, dünya genelinde bireyleri, aileleri ve toplumları etkileyen yaygın bir sosyal ve ekonomik sorundur. Ekonomik büyümenin azalmasına, sosyal eşitsizliğin artmasına ve olumsuz ruh sağlığı ve refah etkilerine neden olabilir. İşsizlik sorununun olumsuz etkileri genellikle uzun süreli ve geniş kapsamlıdır (Gabrikova vd., 2023, s. 2).

ⁱ Dr. Öğr. Üyesi. İğdır Üniversitesi İktisadi ve İdari Bilimler Fakültesi, İğdır-TÜRKİYE. ORCID: 0000-0003-0998-7211. E-posta: polad.aliyev@igdir.edu.tr
Gönderim (Submission): 02.05.2024. Kabul (Acceptance): 10.06.2024.

İşsizliğin yaygın olduğu ülkelerde, işsiz vatandaşların hayatta kalmasını sağlamak için etkili politikalar ve önlemler bulunmazsa, bu durum kolaylıkla sosyal istikrarsızlığa yol açabilir. Bu da ülkenin kalkınmasını her açıdan olumsuz etkileyebilir (Liu ve Li, 2022, s. 1).

Literatürde İşsizliğin en önemli nedeni olarak nüfus artışı gösterilse de işsizliğe katkıda bulunan bir diğer ana faktör de beşerî kaynakların kaybı gösterilmektedir (Sen vd., 2022, s. 348).

Son yıllarda işsizlik tüm dünyada, özellikle de gençler arasında büyük bir endişe kaynağı olmuştur. Dünya ekonomisi, hammadde fiyatlarının yükselmesi ve enflasyonist baskıların artması gibi faktörlerle karşı karşıyadır. Bu durum, ihracatın ve ekonomik büyümenin düşmesine yol açan karmaşık bir uluslararası ekonomik ortam oluşturmuştur. Dolayısıyla, işsizliğin dikkat çekici düzeye ulaşmasına neden olmuştur (Liu ve Li, 2022, s. 1; Sen vd., 2022, s. 348).

Tahmin ve öngörü, tüm alanlarda olduğu gibi emek piyasası verileri için de önem arz etmektedir. Politika yapıcılar, bu verileri kullanarak çeşitli ekonomik göstergeler için gelecekteki eğilimleri karar alma süreçlerinde dikkate alırlar (Chen, 2008, s. 278).

İşsizlik ve özellikle uzun süreli işsizlik riskinin tahmini, işsizlik sigortası kurumları ve müşterileri için de önemlidir. Uzun süreli işsizlik, toplumsal açıdan son derece önemli bir sorundur ve bireyin kariyer beklentileri ve genel yaşam kalitesi üzerinde kalıcı etkiler bırakabilir. Ayrıca, işsizlikle bağlantılı kamu kurumlarının bütçeleri işsizlik miktarına bağlı olduğundan, faaliyetlerinin kapsamını uzun dönemli işsizlik oranlarına bağlı olarak şekillendirirler (Van den Berg vd., 2023, s. 2).

Bu nedenle, işsizlik sorununu en aza indirecek çözümlere yol açacak analiz ve çalışmalara yardımcı olacağı için bu tür araştırmalara ihtiyaç duyulmaktadır. Son araştırmalarda Yapay Zekâ ve Makine Öğrenimi metodlarının, işsizlik durumu hakkında daha iyi bir vizyon sağlamak için işsizlik oranlarının tahmin edilmesine büyük ihtiyaç duyulduğu gözlemlenmiştir (Sen vd., 2022, s. 348).

LİTERATÜR İNCELEMESİ

Yapay Zekâ ve makine öğrenme yöntemlerini kullanarak emek piyasasıyla bağlı tahminleri yapma konusunda çok sayıda ampirik çalışma bulunmamakla birlikte bu konuda yapılmış bazı örnek çalışmalar şu şekildedir:

Chen (2008) çalışmasında, seçilmiş 10 ülkenin 2000-2005 yılları arasındaki aylık verilerini kullanarak 2006 yılı için işsizlik oranlarını doğrusal olmayan Gri Bernoulli modeli (NGBM) vasıtasıyla tahmin etmeyi amaçlamıştır. Bulgular, 2006 yılı için Avrupa Topluluğu ülkelerinin yüksek işsizlik oranlarından mustarip olmaya devam edeceğini göstermiştir. Ayrıca, bulgular Asya'da işsizlik durumunun güçlü ekonomik toparlanma ile iyileşeceğini, Amerika Birleşik Devletleri ve Kanada'da ise işsizlik seviyelerinin sabit kalacağına dair kanıtlar sunmuştur.

Olmedo (2014) çalışmasında İspanya'da işsizliğin tahmin edilmesi için Yakın Komşu ve Sinir Ağı Teknikleri kullanılmıştır. Araştırmanın temel amacı, yeniden yapılandırma ve öğrenme yaklaşımları arasındaki farka vurgu yaparak alternatif parametrik olmayan tahmin tekniklerinin karşılaştırılmasıdır. Birinci yöntemde tek adımlı tahmin, ikincisinde ise daha uzun bir zaman ufku kullanılarak tahmin yapılmıştır. Yöntemlerin sağlamlığını ve genelliğini değerlendirmek için daha sonra bu yöntemler farklı Avrupa ülkelerinin işsizlik zaman serilerine de uygulanmıştır. Sonuç olarak, daha uzun vadeli tahminlerle çalışıldığında sonuçlar açıkça daha iyi olacağı ortaya çıkmıştır.

Stasinakis ve diğerlerinin (2016) çalışmalarında, ABD işsizlik oranının tahmininde radyal tabanlı sinir ağlarının etkinliğini araştırmakta ve tahmin kombinasyonları teknikleri olarak

Kalman filtresi ve Destek Vektör regresyonu incelemiştir. Modellerin istatistiksel performansının belirlenmesi için 1972-2012 dönemi verileri, test verisi için verinin son yedi yılı kullanılmıştır. Sonuçlar, radyal temel fonksiyon sinir ağının tüm modellerin bireysel performanslarından istatistiksel olarak daha iyi performans gösterdiğini ortaya koymaktadır. Hem Kalman filtresi hem de destek vektör regresyon teknikleri istatistiksel doğruluğu artırdığı için tahmin kombinasyonları başarılı olmuştur.

Yıldırım ve Başeğmez'in (2017) çalışması, Türkiye İşsizlik Oranı'nı tahmin etmek için çeşitli zaman serisi tahmin tekniklerini değerlendirmiştir. Bu teknikler arasında Hareketli Ortalamalar (MA), Tek Üstel Düzgünleştirme (SES), Uyarlanabilir Tepki Oranı Üstel Düzgünleştirme (ARRES), Holt'un Doğrusal ve Holt-Winter'in Trend ve Mevsimsellik metotları bulunmaktadır. Çalışmanın sonuçlarına göre, Türkiye İşsizlik Oranı'nı tahmin etmek için en düşük Ortalama Kare Hatası (MSE) değerini elde eden yöntem ARRES yöntemidir.

Mulaudzi ve Ajoodha (2020) makalelerinde, Güney Afrika işsizlik oranını tahmin etmek için altı geleneksel istatistiksel model, yedi makine öğrenimi modeli ile karşılaştırarak tek değişkenli makine öğrenimi tekniklerini araştırmışlar. Çok katmanlı *perception* en düşük hata oranına ulaşırken, Ridge regresyon modeli en yüksek R^2 değerine ulaşmıştır. Bunları ARIMA, LASSO ve elastik ağ yakından takip etmektedir ve makine öğrenimi modellerinin Güney Afrika işsizlik oranını geleneksel istatistiksel yöntemlerden daha yüksek doğrulukla tahmin edebildiğini göstermektedir.

Li ve Yang'un (2021) çalışmalarında, mezunların istihdam durumunu öngörmek için kullanılan LSTM tahmin modelinin performansını artırmayı hedefleyen birçok katmanlı grid search tabanlı parametre optimizasyon algoritması geliştirilmiştir. Elde edilen sonuçlar, mezunların istihdam durumunu analiz etmede LSTM tahmin modelinin ve parametre optimizasyon algoritmasının uygulanabilirliğini ve doğruluğunu ortaya koymaktadır

Hatipoğlu ve diğerleri (2021) Türkiye'deki işsizlik oranlarını tahmin etmek için kullandıkları kNNR, ridge regresyon ve doğrusal regresyon yöntemlerinin performanslarını karşılaştırmışlardır. Yapılan analiz sonuçları, kNNR yönteminin belirleme katsayısının (R^2) diğer yöntemlere kıyasla daha üstün bir performans sergilediğini göstermektedir.

Ahmad ve diğerlerinin (2021) araştırmaları, Avrupa'nın seçilmiş ülkelerinden, özellikle Fransa, İspanya, Belçika, Türkiye, İtalya ve Almanya'da işsizlik oranını daha hassas bir şekilde tahmin etmek için doğrusal ve doğrusal olmayan modellerle desteklenen hibrit tahmin yaklaşımlarını incelemiştir. Çalışmanın bulgularına göre, bu hibrit modeller arasında, Fransa, Belçika, Türkiye ve Almanya için hibrit ARIMA-ARNN tahmin modeli iyi performans gösterirken, İspanya ve İtalya için hibrit ARIMA-SVM modeli üstün performans sergilemiştir. Bu modeller, gelecek tahminleri için kullanılmıştır. Araştırmanın sonuçları, COVID-19 pandemisinin bir sonucu olarak işsizlik oranının önümüzdeki yıllarda artacağını ve bu ülkelerde pandeminin etkisinin en az 5 yıl devam edeceğini göstermektedir.

Mutascu (2021) makalesinde, ampirik olarak da desteklenen teorik bir model kullanarak, yapay zekanın en ileri teknolojiye sahip ve gelişmiş ülkelerdeki işsizlik üzerindeki etkisini araştırmıştır. Ampirik metodoloji, Panel Eşik ve GMM-sistem tahminlerini kullanarak doğrusal olmayan bir yaklaşım izlemektedir. Veri seti 1998-2016 dönemini kapsamakta ve 23 ülkeyi içermektedir. Sonuçlar, yapay zekanın işsizlik üzerinde doğrusal olmayan bir etkisi olduğunu, yapay zekâ kullanımının hızlanmasının işsizliği azalttığını, ancak bunun sadece düşük enflasyon seviyelerinde gerçekleştiğini göstermektedir. Bu durumda, "yer değiştirme etkisi" ile "ikame etkisi" arasında bir "geçiş etkisi" kaydedilmemiştir.

Dzhunkeev (2022) çalışmasında, rastgele orman, gradyan artırma, elastik ağ ve sinir ağları gibi çeşitli makine öğrenimi yöntemlerini kullanarak Rusya'daki işsizlik dinamiklerini tahmin etmeği amaçlamıştır. Bulgular, gradyan artırma modelinin tahmin sürecinde daha iyi uyum sağladığını göstermiştir.

Ho (2022) çalışmasında, Pesaran ve Pick (2011) tarafından ortaya atılan ortalama pencere tahminlerine (AveW) hem makine öğrenimi hem de standart ARMA tabanlı zaman serisi yaklaşımları uygulamıştır. Model belirsizliklerini hesaba katmak için, AveW'lerin ortalaması alınarak elde edilen tahmin kombinasyonunun oldukça başarılı olduğu gözlemlenmiştir. Özellikle, performans karşılaştırması ortak değişkenlerin olmadığı durumda, makine öğrenimi yöntemlerinin standart zaman serisi modellerinden önemli ölçüde daha iyi performans gösterdiğini belirlemiştir. Ayrıca ortak değişkenli durum için ise hem ARMA tabanlı hem de makine öğrenimi yöntemlerinin eşit derecede iyi performans gösterdiği gözlemlenmiştir. Şaşırtıcı bir şekilde, iyi bilinen derin öğrenme yöntemi tekrarlamalı (yenilemeli) sınır ağlarının (RNN) bir çeşidi olan Uzun ve kısa süreli belleğin (LSTM) beklenenden daha iyi bir performansla sahip olmadığı tespit edilmiştir. Bu sonuçlar, AveW'nin zaman serisi tahmini için makine öğrenimiyle birlikte kullanılabilir bir kullanışlı bir çerçeve olduğunu göstermektedir.

Sen ve diğerleri (2022), çalışmalarında, Hindistan'ın istihdam olanaklarını artırmaya ciddi ihtiyaç duyan eyaletlerini tespit etmek için Lojistik Regresyon, Destek Vektör Makineleri, K-en yakın komşu (kNN) algoritması ve Karar Ağaçları gibi farklı popüler Denetimli Makine Öğrenimi algoritmalarını kullanmıştır. Bulgular karar ağaçlarının daha iyi performans gösterdiğini ortaya koymuştur.

Karahan ve Çetintaş'ın (2022), Türkiye'nin 2005-2018 dönemine ait aylık temel ekonomik göstergeleri kullanarak gelecek dönemler için işsizlik oranı tahmini yapmayı amaçlamaktadır. Bu tahmin çalışması için toplam altı temel ekonomik göstergenin verileri kullanılmıştır. Yapılan bu tahmin çalışması sonucunda, geleneksel yöntemlerle yanlış sonuçlar elde etme riskinin yüksek olduğu, kısmen hatalı veya aşırı sapmalı veriler içeren kaotik problemlerin çözümünde çağdaş yöntemlerden biri olan YSA (Yapay Sinir Ağları) yönteminin tahminin gerçeğe oldukça yakın ve güvenilir sonuçlar verdiği tespit edilmiştir.

Yamacli ve Yamacli'nın (2023) çalışması, işsizlik oranını tahmin etmek için geleneksel doğrusal ARIMA ve doğrusal olmayan yapay sinir ağı (YSA) regresyon modellerini karşılaştırmıştır. Çalışmada, 01.01.2008 ile 31.08.2022 tarihleri arasındaki veriler kullanılmıştır. Çalışmanın sonuçlarına göre, geleneksel doğrusal ARIMA modeli, genel olarak işsizlik oranını tahmin etmek için uygun bir model olarak belirlenmiştir. Ancak, pandeminin etkisi altında, özellikle 2020-2021 döneminde, ARIMA modelinin tahmin hatalarının yapay sinir ağı modelinden daha yüksek olduğu bulunmuştur. Bu durum, ekonomik belirsizlik dönemlerinde yapay sinir ağı modellerinin daha esnek ve etkili olabileceğini göstermektedir.

Gabrikova ve diğerleri (2023) çalışmasında Slovakya'da iş arayanların CART, CHAID ve Diskriminant analizi gibi üç ayrı modelden tahminleri birleştirerek istifleme yöntemini kullanmıştır. Nihai meta-model lojistik regresyon kullanılarak oluşturulmuştur ve işsizlik süresinin tahmininde neredeyse %78'lik bir genel doğruluk oranına ulaşılmıştır.

Van den Berg ve diğerleri (2023), Rassal Orman makine öğrenimi yöntemleri kullanarak işsizlik sigortası kurumları, planlamacı ve politikacılar için önemli olan 6 ay içinde yeniden istihdam edilme olasılığını tahmin etmeye çalışmıştır.

Celbiş (2023) kırsal bölgelerde sürdürülebilirliği artırabilecek politikalar hakkında bilgi sağlamak amacıyla ağaç tabanlı sınıflandırma modellerini kullanarak işsizlikle ilgili temel bireysel faktörleri araştırmıştır. Bu amaçla, sınıflandırma ağacı, Bagging, Rassal Orman, Gradyan Artırma ve Stokastik Gradyan Artırma gibi çeşitli makine öğrenimi teknikleri

kullanılmıştır. Ayrıca, SHAP değer analizi gibi çıkarımsal tekniklerle model sonuçları değerlendirilmiştir.

Çalışmanın sonuçları, eğitim programlarına erişim, eğitim seviyeleri, cinsiyet, yaş ve ebeveynlerin eğitim seviyeleri gibi farklılıkların işgücü piyasasındaki eşitsizlikleri etkileyebileceğini göstermektedir.

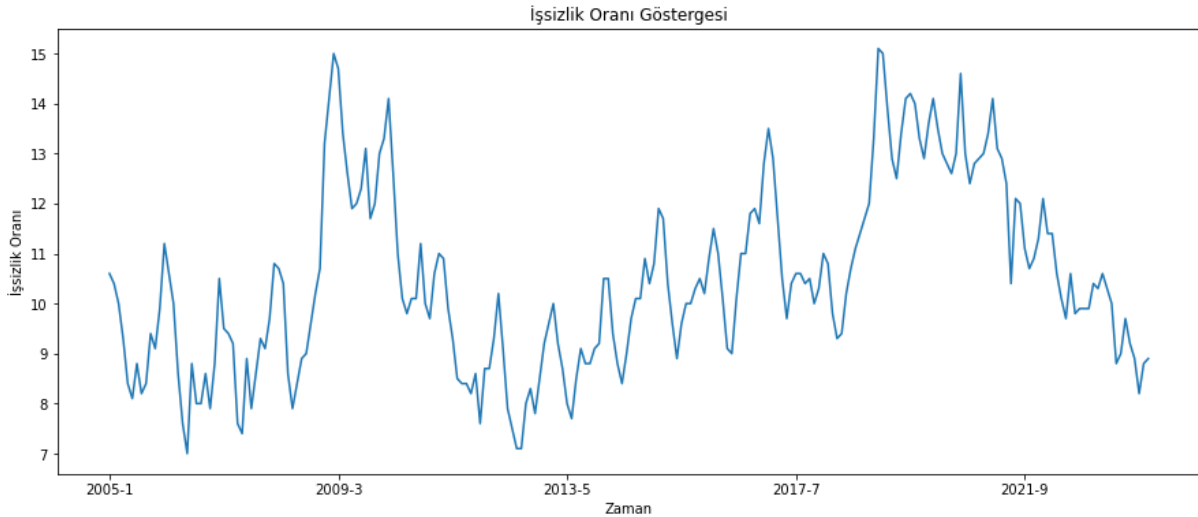
Yurtsever (2023), Ocak 1983 ile Mayıs 2022 arasındaki aylık işsizlik oranı verilerini kullanarak Amerika Birleşik Devletleri, Birleşik Krallık, Fransa ve İtalya'daki işsizlik oranlarını tahmin etmek için LSTM ve GRU (Geçitli Yinelemeli Birim) katmanlarının birleştirildiği bir model uygulamıştır. Elde edilen sonuçlar, hibrit modelin İtalya dışındaki dört ülke için daha iyi performans gösterdiğini göstermektedir.

Araştırmamızda ARIMA, SARIMA, XGboost, Rassal Orman GRU, LSTM algoritmaları kullanılmıştır.


YÖNTEM

Veri Seti

Bu analiz için kullanılan işsizlik verileri Türkiye İstatistik Kurumu (TÜİK) sitesinden elde edilmiştir. Zaman serisinde Ocak 2005'ten Aralık 2023'a kadar Türkiye Cumhuriyeti'nde mevcut olan işsizlik oranına ilişkin toplam 228 aylık gözlem bulunmaktadır. Şekil 1'de bu verilerin grafiği gösterilmektedir. Dönem boyunca ortalama işsizlik oranı %10,46, en düşük işsizlik oranı 2006'larda %7 ve en yüksek işsizlik oranı 2019 yılında raporlanan %15,1'dir. Şekil 2'de Türkiye'de işsizlik oranının normal bir dağılım izlemediği açıkça görülmektedir. Tek değişkenli geleneksel istatistiksel yöntemlerin otoregresif yapısı genellikle verilerin sıfır ortalama ve sabit varyansa sahip normal bir dağılım izlediğini varsayar. Normallik için iyi bilinen testler olan Kolmogorov-Smirnov ve Shapiro-Wilk testleri de yapılmıştır ve her ikisi de işsizlik oranının normal dağılmadığını doğrulamıştır.




Şekil 1. Ocak 2005 ve Aralık 2023 Tarihleri Arasında Türkiye'de İşsizlik Oranı



Şekil 2. İşsizlik Oranı Verisinin Olasılık Dağılımı

Zaman serisi verileri üç temel bölüme ayrıştırılabilir: trend, mevsimsellik ve artıklar. Şekil 3 (a)'den Türkiye işsizlik oranı verilerinin trend içermediği görülmektedir. Her yıl verilerde tekrarlanan hareketler verinin mevsimsel olduğunu göstermektedir (Şekil 3 (b)). Artıkların incelenmesiyle, varyasyonda 2019 ve 2021 yılları arasında verilerde önceki tüm dönemlerden daha fazla değişkenlik olduğu görülebilir Şekil 3 (c). Augmented Dickey-Fuller (ADF) testi sonuçları verinin düzey değerlerinde durağan olmadığını göstermektedir.




Şekil 3. Ocak 2005 -Aralık 2023 Türkiye'de İşsizlik Oranı Verilerinin Trend, Mevsimsellik ve Artıklara Ayrıştırılması

Araştırma Modelleri

XGBoost

XGBoost, Friedman (2001) tarafından geliştirilen Gradient Boosting (GB) yöntemi temelli bir algoritmadır. XGBoost, hız ve performans için tasarlanmış, gradyan destekli karar ağaçlarının bir uygulamasıdır (Ma vd., 2018). XGBoost GB'tan farklı olarak, aşırı öğrenmeyi kontrol etmek için daha düzenli bir model biçimlendirir ve daha iyi performans sağlar (Carmona vd., 2019). XGBoost, son zamanlarda yapılandırılmış veya tabular verileri için uygulamalı makine öğrenimi ve Kaggle yarışmalarına hâkim olan bir algoritmadır (Abar, 2020, s. 434).



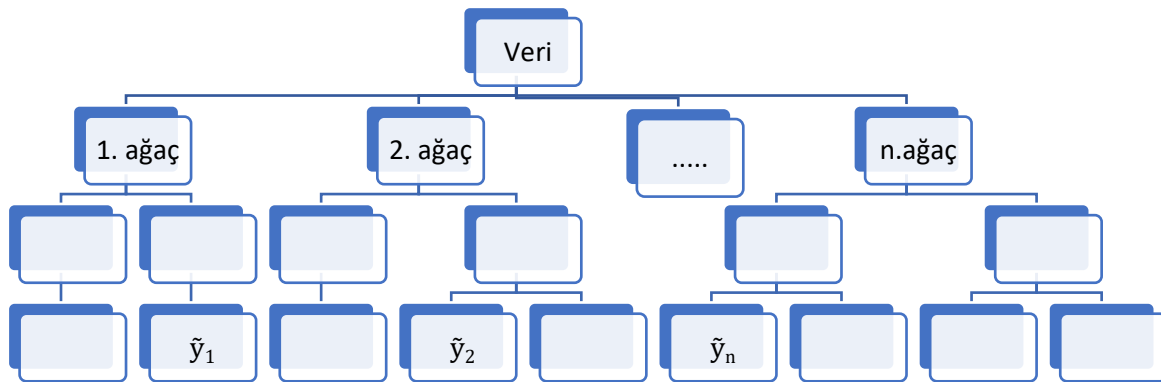
Şekil 4. XGBoost Modelinin Mimarisi

Gradyan artırma, önceki modellerin artıklarını veya hatalarını tahmin eden yeni modellerin yaratıldığı ve daha sonra son tahmini yapmak için bir araya getirildiği bir yaklaşımdır. Yeni modeller eklerken kaybı en aza indirmek için bir gradyan iniş algoritması kullandığından gradyan artırma olarak adlandırılır. Bu yaklaşım hem regresyon hem de sınıflandırma tahmini modelleme problemlerini destekler.

XGBoost'ta ilk adım ilk tahmini (base score) yapmaktır. Bu tahmin, bundan sonraki adımlarda yapılacak işlemler ile yakınsayarak doğru sonuca ulaşılacağı için herhangi bir sayı olabilir (Brownlee, 2018).

Rassal Orman Regresyonu

Rassal Ormanlar (RO) yöntemi, 2001 yılında Leo Breiman tarafından geliştirilmiştir ve karar ağaçlarına dayanmaktadır. Bu yöntem genellikle sınıflandırma analizleri için kullanılmakla birlikte regresyon problemleri için de uygulanabilmektedir (Altındağ, 2020).



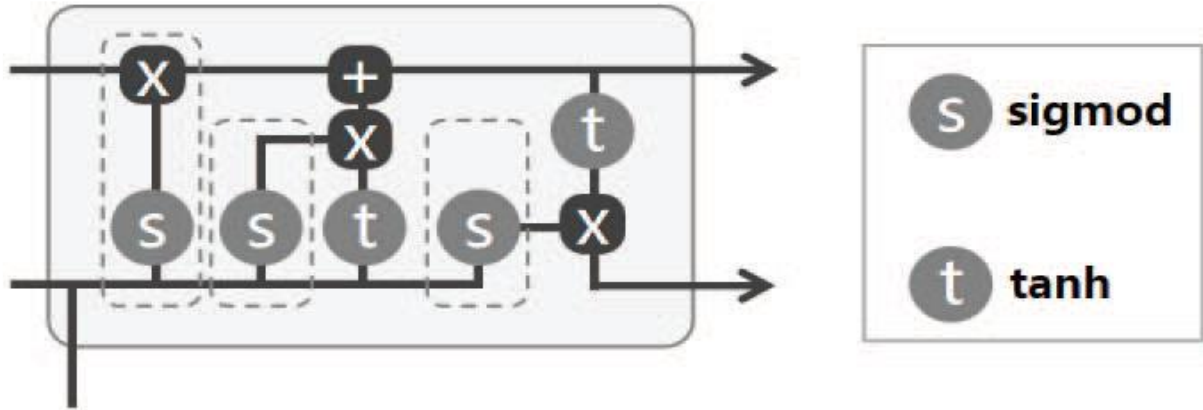
Şekil 5. Rassal Orman Regresyonunda Ağaçların Oluşumu ve Tahmini

Araştırmacılara göre, Rassal Orman (RO) modelleri destek vektör makineleri (SVM) veya yapay sinir ağları (YSA) gibi diğer popüler makine öğrenme tekniklerine veya diğer karar ağaç algoritmalarına göre çok iyi sonuçlar sağlamaktadır (Altındağ, 2020).


LSTM ve GRU

Yapay Sinir Ağları modelinin genel olarak mevcut verilerin tahmin edilmesi açısından oldukça başarılı olduğu görülmüştür. Tahmini performansların karşılaştırmalı olarak incelenmesinin çok daha verimli sonuçlar vereceği düşünülmektedir (Çelik, 2019). Yapay sinir ağları, özellikle de uzun-kısa vadeli bellek (LSTM) ve kapı odaklı birimler (GRU) gibi çeşitli Tekrarlayan sinir ağı (RNN) modelleri, zaman serilerinin tahmininde önemli bir rol oynar. Bunun temel nedeni tekrarlayan sinir ağlarının (RNN) sıradan yapay sinir ağlarından (ANN) farklı olarak, sıralı verileri iyi işleyebilmesidir. LSTM ve GRU gibi RNN modelleri, geleneksel sinir ağlarından farklı olarak geçmiş zaman adımlarındaki bilgiyi saklayabilme yeteneğine sahiptir. Bu özellik, zaman serilerindeki uzun vadeli bağımlılıkları ve karmaşıklıkları ele almak için son derece değerlidir. Bu modeller, zaman serilerinin içerdiği karmaşık ilişkileri ve zaman içindeki desenleri daha iyi yakalayabilme yetenekleri ile bilinirler. Bu nedenle, LSTM ve GRU gibi RNN modelleri, zaman serileri tahmini gibi birçok uygulamada tercih edilen ve başarılı bir şekilde kullanılan yapay zekâ yöntemleridir (Çöltekin ve Rama, 2018).

LSTM ilk olarak 1997 yılında Sepp Hochreiter ve Jurgen Schmidhuber tarafından tanıtılmış, bugüne kadar yaygın olarak kullanılmış ve birçok varyantı geliştirilmiştir. Sıradan RNN ile karşılaştırıldığında LSTM, gradyan kaybolması ve gradyan patlaması sorununu çözmek için giriş kapısı ve unutma kapısı ekler, böylece uzun vadeli bilgiler yakalanabilir ve uzun dizili metinlerde daha iyi performansa sahip olabilir. GRU'nun giriş ve çıkış yapısı sıradan RNN'ye benzer, ancak içyapısı LSTM'ye benzer (Hettiarachchi ve Ranasinghe, 2019). LSTM ve GRU'nun içyapı karşılaştırması aşağıdaki Şekil 6 ve Şekil 7'de gösterilmiştir.



Şekil 6. LSTM Modelinin Mimarisi



Şekil 7. GRU Modelinin Mimarisi

LSTM, uzun vadeli bağımlılıkları daha etkili bir şekilde öğrenebilirken, GRU daha basit bir yapıya sahip olup daha hızlı eğitim süreleri ve daha az parametre ile daha düşük hesaplama maliyeti sağlar (Yang vd., 2020).

Analizlerde pmdarima -2.0.4 statsmodels -0.14.0, matplotlib-3.8.0, sklearn-1.2.2, tensorflow -2.12.0, xgboost-2.0.3 kütüphane versiyonları kullanılmıştır. Analizler Jason Brownlee'nin kodlarından uyarlanmıştır (Brownlee, 2020a; Brownlee, 2020b; Brownlee, 2021).

BULGULAR

Bir zaman serisi veri kümesi için bir sayı dizisi verildiğinde, denetimli bir öğrenme problemi gibi görünmek için verileri yeniden yapılandırabiliriz. Bunu önceki zaman adımlarını girdi değişkenleri olarak kullanarak ve bir sonraki zaman adımını çıktı değişkeni olarak kullanarak yapabiliriz.


Bir sonraki zaman adımındaki değeri tahmin etmek için önceki zaman adımındaki değeri kullanarak bu zaman serisi veri setini denetimli öğrenme problemi olarak yeniden yapılandırabiliriz.

Tablo 1. Modellerinin Performansını Karşılaştıran Model Değerlendirmesi

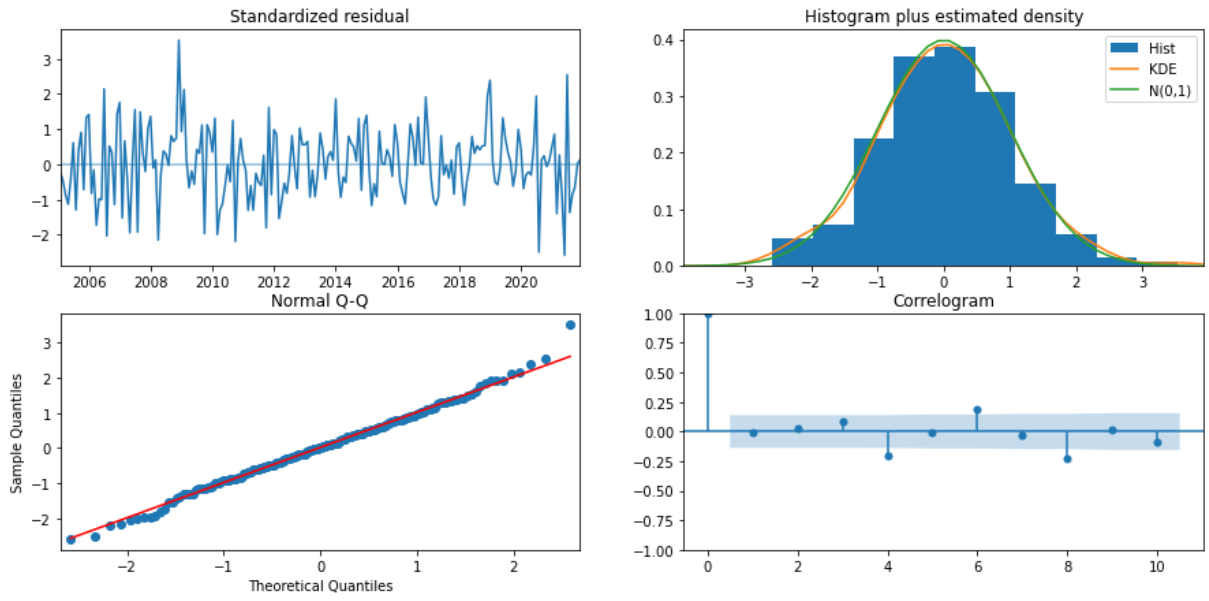
	MSE	RMSE	MAE	MAPE	R ²
ARIMA	4.328	2.080	1.888	19.963	-4.169
SARIMA	0.2956	0.5437	0.4517	4.7351	0.6471
XGboost	1.037	1.018	0.744	0.070	0.660
RO	0.595	0.772	0.811	0.052	0.805
LSTM	0.904	0.951	0.747	0.067	0.704
GRU	0.557	0.746	0.567	0.049	0.818

Ölçüt model olarak kullanılan ARIMA (1,1,2) ve SARIMA (3,1,0)(1,0,1)[12] modellerine göz attığımızda ikincinin tahmin grafiğinin (Şekil 8 ve Şekil 10) ve performans göstergelerinin daha iyi olduğunu görmekteyiz. Genel yazılım şekli ARIMA (p,d,q) olan modelde p ve q parametreleri Otoregresif (AR) kısmındaki gecikme sayısı ve Hareketli ortalama (MA) kısmındaki gecikme sayısını temsil ederken, d durağanlığı sağlamak için zaman serisinin farklılaştırılma derecesini göstermektedir (Borkar, 2016). ARIMA modeline benzeyen fakat daha gelişmiş bir versiyon olan SARIMA modeli, genellikle SARIMA (p, d, q) (P, D, Q)m olarak belirtilir. Zaman serisinin mevsimsel bileşenlerini açıklamak için ARIMA modeline kıyasla dört ek parametre içerir. Bu parametrelerden p, q ve d sırasıyla trend bileşeninin otoregresif düzenini, fark alma derecesini ve hareketli ortalama sırasını belirtir. P, D ve Q ise mevsimsel bileşenin derecelerini ifade eder. m parametresi ise bir mevsimsel dönemdeki zaman adımlarını gösterir (Çiftçi ve Batur Sir, 2023). Her iki modelin tanısal testlerinin grafik görselleri (Şekil 9 ve Şekil 11) model tahminlerinin uygun olduğunu göstermesine rağmen, ARIMA (1,1,2) modelinin Belirleme Katsayısının (R²) negatif ve birden büyük olması dikkat çekicidir. Aşağıdaki R² hesaplama formülünü yansıtan Denklem (1) göz önüne alındığında, bu durum modelin hata varyansının (SSR) toplam varyanstaki (SST) daha yüksek olduğunu gösterir, dolayısıyla modelin geçersiz olduğuna işaret etmektedir.

$$R^2 = 1 - (SSR / SST) \quad (1)$$




Şekil 8. ARIMA (1,1,2) Modeli Tahmini

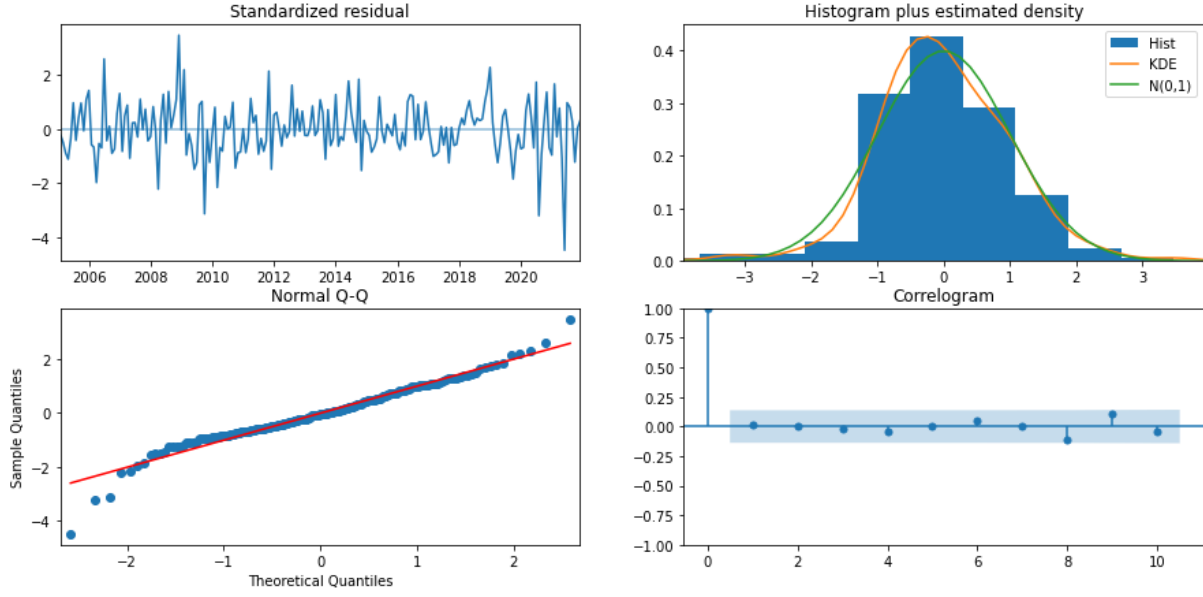


Şekil 9. ARIMA (1,1,2) Modeli Tanımsal Test Sonuçları

MAPE hariç diğer tüm hata ölçütleri, SARIMA modelinin hata ölçütlerinden büyük olmasına rağmen, tüm Makine Öğrenimi modellerinin R^2 değeri SARIMA modellerinin R^2 değerinden büyüktür.




Şekil 10. SARIMA (3,1,0) (1,0,1) [12] Modelinin Tahmini




Şekil 11. SARIMA (3,1,0) (1,0,1) [12] Modeli Tanımsal Test Sonuçları


Gördüğümüz üzere, en iyi metrik göstergeler sergileyen yöntem GRU modelidir. Bu modelin MAE ve MSE değerleri diğer makine öğrenimi metotlarıyla karşılaştırıldığında en düşüktür ve R^2 değeri en yüksektir. Buna en yakın göstergeleri Rassal Orman modeli sergilemektedir. Aşağıdaki grafiklerden GRU ve Rassal Orman modellerinin test ve tahmin değerlerinin diğer modellere kıyasla daha uygun olduğunu görmekteyiz.




Şekil 12. LSTM Modeli Test ve Tahmin Değerleri




Şekil 13. GRU Test ve Tahmin Değerleri



Şekil 14. Rassal Orman Regresyonu Test ve Tahmin Değerleri



Şekil 15. XGboost Regresyonu Test ve Tahmin Değerleri



Şekil 16. Makine Öğrenimi Modellerinin Test ve Tahmin Değerleri

Gözlenen değerler ile tüm modellerin tahmini değerlerinin birlikte verildiği grafiğe baktığımızda yapay sınır ağı modellerinin tahmin değerlerinin grafiğinin seyrinin diğer modellerin grafikleri ile kıyasta gözlenen değerlerin grafiklerine daha çok benzediğini görmekteyiz. Bunun yanı sıra GRU ve Rassal Orman Regresyonu Modellerinin Tahmin değerlerinin grafiğinin diğerleri ile kıyasta gözlenen değerlerin grafiğine daha yakın olduğunu görmekteyiz.

SONUÇ

İşsizlik tüm ülkelerin en büyük sorunlarından biridir. Son yirmi yıldır belirgin bir çözüm olmaksızın büyüyen bir sorundur. Bu yönde oluşturulan politikaların başarısı, işsizlik oranının doğru ve anlamlı bir şekilde tahmin edilmesine dayanır. Halihazırda bu tahminler, diğer araçların yanı sıra geleneksel istatistiksel yöntemlerle gerçekleştirilmektedir. Bu çalışma,

makine öğrenimi modellerinin sadece Türkiye’de işsizlik oranının tek değişkenli tahminindeki hata oranlarını azaltmakla kalmayıp, aynı zamanda işsizlik oranlarının hareketinin altında yatan kalıpları da yakalayabildiğini göstermiştir.

Yaptığımız analizler GRU ve Rassel Orman ve regresyonların etkisinin söz konusu veride daha yüksek olduğunu göstermektedir. Zaman serileri tahmin yöntemleri içinde bu modeller yapay zekâ modelleri ve diğer makine öğrenilmesi modelleri ile kıyasta daha iyi sonuçlar vermiştir. Modeller, Türkiye işsizlik oranının doğrusal olmayan yapısını yakalamıştır. Elde edilen sonuç bu iki algoritmanın sadece tek değişkenli analizlerde değil çok değişkenli zaman serilerinde de etkin yöntem ola bileceği yönünde bilgi vermektedir.

Makalemizde ARIMA ve SARIMA modelleri işsizlik oranlarının tahmininde ortodoks ölçütler olarak kabul edilmiştir. SARIMA modeli ile karşılaştırdığımızda, ele aldığımız makine öğrenimi modellerinin hepsinin RMSE ve MAE değerleri bu modelin değerlerinden daha yüksek tahmin hata oranları elde etmiştir. Diğer makine öğrenimi metodlarının R^2 performans değeri SARIMA modelinden yüksek olurken, MAPE değerleri bu modelin MAPE değerinden düşük olmuştur. Dolayısıyla bu araştırma, makine öğrenimi tekniklerinin Türkiye’de işsizlik oranının tek değişkenli tahminine uygulanabilir bir alternatif olduğunu göstermiştir. Modeller, işsizlik oranlarının doğrusal olmayan hareketlerini yakalayabilmiş ve çoğu durumda yöntemlerde geleneksel istatistiksel yöntemlerden daha düşük hata oranlarına sahip tahminler üretebilmiştir.

KAYNAKÇA

- Abar, H. (2020). Xgboost ve Mars yöntemleriyle altın fiyatlarının kestirimi. *EKEV Akademi Dergisi*, 24(83), 427-446.
- Ahmad, M., Khan, Y. A., Jiang, C., Kazmi, S. J. H. ve Abbas, S. Z. (2021). The impact of COVID-19 on unemployment rate: An intelligent based unemployment rate prediction in selected countries of Europe. *International Journal of Finance & Economics*, 28, 528–543 <https://doi.org/10.1002/ijfe.2434>
- Altındağ, İ. (2020). Karar ağacı ve rassal orman regresyon modeli. *Veri madenciliğinde kullanılan regresyon modelleri ve R ile uygulamalı örnekler*, Ö. Fruk Rençber (der.) içinde, 35-54.
- Borkar, P. (2016). Modeling of groundnut production in India using ARIMA Model. *International Journal of Research IT Management*, 6(3), 36–44.
- Brownlee, J. (2018). *XGBoost with Python*. Machine Learning Mastery.
- Brownlee, J. (2020a). Time series forecasting with the Long Short-Term Memory Network in Python. *Machine Learning Mastery*. <https://machinelearningmastery.com/time-series-forecasting-long-short-term-memory-network-python/>
- Brownlee, J. (2020b). Random forest for time series forecasting. *Machine Learning Mastery* <https://machinelearningmastery.com/random-forest-for-time-series-forecasting/>
- Brownly, J. (2021). How to use XGBoost for time series forecasting. *Machine Learning Mastery* <https://machinelearningmastery.com/xgboost-for-time-series-forecasting/>
- Carmona, P., Climent, F. ve Momparler, A. (2019). Predicting failure in the U.S. banking sector: An extreme gradient boosting approach. *International Review of Economics & Finance*, 61, 304-323.
- Celbiş, M. G. (2023). Unemployment in rural Europe: A machine learning perspective. *Applied Spatial Analysis and Policy*, 16, 1071–1095. <https://doi.org/10.1007/s12061-022-09464-0>
- Çelik, Ş. (2019). Estimation of the orange production in Turkey by means of artificial neural networks. *Global Journal of Engineering Science and Researches*, 6(9), 10-16.
- Chen, C. (2008). Application of the novel nonlinear grey Bernoulli model for forecasting unemployment rate. *Chaos, Solitons and Fractals*, 37, 278–287.
- Çiftçi, S. ve Sir, B. G. D. (2023). Acil servise başvuru sayısının zaman serisi analiz ve makine öğrenmesi yöntemleri ile tahmin edilmesine yönelik bir uygulama. *Pamukkale Üniversitesi Mühendislik Bilimleri Dergisi*, 29(7), 667-679.

- Çöltekin, Ç. ve Rama, Ta. (2018). Tübingen-Oslo at SemEval-2018 Task 2: SVMs perform better than RNNs in Emoji Prediction. In *Proceedings of the 12th International Workshop on Semantic Evaluation* (ss. 34–38). Association for Computational Linguistics.
- Dzhunkeev, U. (2022). Forecasting unemployment in Russia using machine learning methods. *Russian Journal of Money and Finance*, 81(1), 73–87.
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of Statistics*, 29(5), 1189-1232.
- Gabrikova, B., Svabova, L. ve Kramarova, K. (2023). Machine learning ensemble modelling for predicting unemployment duration. *Applied Sciences*, (13), 10146.
- Hatipoğlu, Ş., Belgrat, M. A., Degirmenci, A. ve Karal, Ö. (2021). Prediction of unemployment rates in Turkey by k-Nearest Neighbor regression analysis. In *2021 Innovations in Intelligent Systems and Applications Conference (ASYU)* (ss. 1-5). IEEE.
- Hettiarachchi, H. ve Ranasinghe, T. (2019). Emoji powered capsule network to detect type and target of offensive posts in social media. In *Proceedings of the International Conference on Recent Advances in Natural Language Processing (RANLP 2019)* (ss. 474–480). INCOMA Ltd.
- Ho, T. (2022). Forecasting unemployment via machine learning: The use of average windows forecasts. SSRN. <http://dx.doi.org/10.2139/ssrn.3496138>
- Karahan, M. ve Çetintaş, F. (2022). Forecasting of Turkey's unemployment rate for future periods with artificial neural networks. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (62), 163-184. <https://doi.org/10.18070/erciyesiibd.1056618>
- Liu, X. ve Li, L. (2022). Prediction of labor unemployment based on time series model and neural network model. *Hindawi, Computational Intelligence and Neuroscience*.
- Li, X. ve Yang, T. (2021). Forecast of the employment situation of college graduates based on the LSTM neural network. *Hindawi Computational Intelligence and Neuroscience*, 1-11.
- Mulaudzi, R. ve Ajoodha, R. (2020). An exploration of machine learning models to forecast the unemployment rate of South Africa: A univariate approach. *2nd International Multidisciplinary Information Technology and Engineering Conference (IMITEC)*, 25-27 Nov. Kimberley, Güney Afrika.
- Mutascu, M. (2021). Artificial intelligence and unemployment: New insights. *Economic Analysis and Policy*, 69, 653-667.
- Ma, X., Sha, J., Wang, D., Yu, Y., Yang, Q. ve Niu, X. (2018). Study on a prediction of P2P network loan default based on the machine learning LightGBM and XGBoost algorithms according to different high dimensional data cleaning. *Electronic Commerce Research and Applications*, 31, 24-39.
- Olmedo, E. (2014). Forecasting Spanish unemployment using near neighbour and neural net techniques. *Computational Economics*, 43, 183–197. <https://doi.org/10.1007/s10614-013-9371-1>.
- Sen, M., Basu, S., Chatterjee, A., Banerjee, A., Pali, S. P. K., ve Mukhopadhyay, Dutta, S. ve Tarafdar, A. (2022). Prediction of unemployment using machine learning approach. In *2022 OITS International Conference on Information Technology (OCIT)* (ss. 1-5). Bhubaneswar, Hindistan.
- Stasinakis, C., Sermpinis, G., Theofilatos, K. ve Karathanasopoulos, A. (2016). Forecasting US unemployment with radial basis neural networks, Kalman filters and support vector regressions. *Computational Economics*, 47, 569–587. <https://doi.org/10.1007/s10614-014-9479-y>
- Van den Berg, G. J., Kunaschk, M., Lang, J., Stephan, G. ve Uhlendorff, A. (2023). Predicting re-employment: Machine learning versus assessments by unemployed workers and by their caseworkers. [IZA DP No. 16426]. IZA Institute of Labor Economics.
- Yamacli, S. ve Yamacli, S. (2023). Estimation of the unemployment rate in Turkey: A comparison of the ARIMA and machine learning models including COVID-19 pandemic periods. *Heliyon*, 9(1), e12796. <https://doi.org/10.1016/j.heliyon.2023.e12796>
- Yang, S., Yu, X. ve Zhou, Y. (2020). LSTM and GRU neural network performance comparison study: Taking Yelp review dataset as an example. In *2020 International Workshop on Electronic Communication and Artificial Intelligence (IWECAI)* (ss. 98-101). Shanghai, Çin.
- Yıldırım, H. ve Başeğmez, H. (2017). Analysis and forecast of Turkey unemployment rate. *Global Journal of Mathematical Analysis*, 5(1), 11-15. <https://doi.org/10.14419/gjma.v5i1.6841>.
- Yurtsever, M. (2023). Unemployment rate forecasting: LSTM-GRU hybrid approach. *Journal for Labour Market Research*, 57(18). <https://doi.org/10.1186/s12651-023-00345-8>