

Atıf İçin: Aliyev, P. (2025). LSTM ve GRU Modellerinde Açıklanabilir Yapay Zekâ Yaklaşımı: İktisadi Veriler Üzerine Bir Uygulama. *İğdır Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 15(2), 396-411.

To Cite: Aliyev, P. (2025). Explainable Artificial Intelligence Approach in LSTM and GRU Models: An Application on Economic Data. *Journal of the Institute of Science and Technology*, 15(2), 396-411.

LSTM ve GRU Modellerinde Açıklanabilir Yapay Zekâ Yaklaşımı: İktisadi Veriler Üzerine Bir Uygulama

Polad ALİYEV¹

Öne Çıkanlar:

- Basit RNN, CNN, LSTM ve GRU derin öğrenme modelleri
- Derin öğrenme modellerini yorumlamak için oyun teorisine dayalı CP-PD profilleri kullanılmıştır
- Yorumlama yöntemleri DL modelinin çıktısını yorumlamak için umut verici araçlardır.

ÖZET:

Çalışmanın temel amacı, mali politikaların istihdam üzerindeki etkisini açıklamalı yapay zekâ metotlarıyla araştırmaktır. Araştırmada, Ocak 2005 ile Ekim 2023 arasındaki döneme ait aylık istihdam, bütçe tahsilatı, bütçe giderleri ve bütçe tahsilatının bütçe giderlerine oranlarına ilişkin veriler kullanılmıştır. Analizde, benzer performans değerlerine sahip olduğu ortaya çıkan LSTM ve GRU modelleri bazında uygulanan açıklamalı yapay zekâ algoritmalarının bulgularının birbirine yakın olması, önemli bir sonuç olarak değerlendirilebilir. Modellerin performans değerleri birbirine yakın olduğu için her iki model bazında XAI yöntemleri kullanılmıştır. Bunun için Dalex paketinin olanaklarından yararlanılmıştır. LSTM ve GRU mimarilerinin yapısı gereği bağımsız değişkenlerin üç boyutlu olması gerekmektedir. Dalex paketinin girdileri ise iki boyutlu veri şeklindedir. Makalenin analiz kısmında paketin bu eksiklikleri yazar tarafından geliştirilen kodlar ile giderilmiştir.

Anahtar Kelimeler:

- LSTM
- GRU
- XAI

Explainable Artificial Intelligence Approach in LSTM and GRU Models: An Application on Economic Data

Highlights:

- Simple RNN, CNN, LSTM and GRU deep learning models
- CP-PD profiles based on game theory were used to interpret deep learning models
- Interpretation methods are promising tools for interpreting the output of the DL model.

ABSTRACT:

The main objective of the study is to investigate the impact of fiscal policies on employment within the framework of economic theories by using explainable artificial intelligence methods. The study uses monthly data on employment, budget revenues, budget expenditures, and the ratio of budget revenues to budget expenditures for the period between January 2005 and October 2023. In the analysis, it can be considered an important result that the findings of the explainable artificial intelligence algorithms applied on the basis of LSTM and GRU models, which are found to have similar performance values, are close to each other. Since the performance values of the models are close to each other, XAI methods were used on the basis of both models. For this, the facilities of the Dalex package were used. Due to the structure of the LSTM and GRU architectures, the independent variables are required to be three-dimensional. The inputs of the Dalex package are in the form of two-dimensional data. In the analysis part of the article, these deficiencies of the package were overcome with the codes developed by the author.

Keywords:

- LSTM
- GRU
- XAI

¹ Polad ALİYEV ([Orcid ID: 0000-0003-0998-7211](https://orcid.org/0000-0003-0998-7211)), İğdır Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, İğdır, Türkiye

Sorumlu Yazar/Corresponding Author: Polad ALİYEV, e-mail: poladali81@gmail.com

GİRİŞ

Bilgisayar bilimlerinin gelişimiyle, özellikle son yıllarda hayatımızın odak noktasına dahil olan yapay zekâ uygulamaları, tüm alanlarda olduğu gibi veri işleme, analiz etme, özellikle modelleri tahmin etme alanlarında da önemli roller üstlenmiştir. Klasik istatistiksel modeller, verilerin stokastik doğasını tanımlamakta yetersiz kalmaktadır. Uzun kısa süreli bellek – LSTM (Long Short Term Memory) ve kapı tekrarlayan geçitler (Gated Recurrent Unit, GRU) gibi sinir ağları, tek değişkenli ve çok değişkenli veriler için iyi tahminicilerdir (Mateus ve ark., 2021). Ancak bir sistemde açıklanabilirlik ile tahmin doğruluğu arasında ters bir ilişki bulunmaktadır (Angelov ve ark., 2021). Sinir ağları gibi opak modeller, açıklanabilirlik sağlamak için sonradan yapılan analizlere (post hoc analiz) ihtiyaç duyan modellerdir (Freeborough ve Zyl, 2022). Sonuç olarak, doğal dil işleme ve bilgisayarla görme gibi görevlerde en yüksek doğruluğu sunan sinir ağları ve derin öğrenme yöntemleri, aynı zamanda en az yorumlanabilir olanlardır. Bu tür modellerin doğrusal olmayan ve karmaşık yapısı, soyut kalıpları öğrenme becerisini sağlarken tahminlerin açıklanmasını zorlaştırmaktadır. Bu nedenle araştırmacılar, bu tür yöntemleri, bilgisayar temelli ayrımcılık ve önyargının devam etme riski taşıyan bir “kara kutu” olarak nitelendirmektedir (Parikh ve ark., 2019). Ayrıca en kötü senaryoda, bir yapay zeka sisteminin nasıl çalıştığını anlamamak, yapay zekanın topluma daha fazla entegre olmasıyla fiziksel zararlara yol açabilir (Caruana ve ark., 2015). Bu zorluklar nedeniyle, son yıllarda makine öğrenimi modellerinin açıklanabilirliğini artırmak ve çıktıların daha iyi anlaşılmasını sağlamak için yeni teknikler ve ilkeler geliştirilmektedir. Bu tür yaklaşımlar, veri biliminde "açıklanabilir yapay zeka" olarak adlandırılmakta olup literatürde "Açıklanabilir Yapay Zeka (XAI)" olarak bilinmektedir (Gunning ve ark., 2019). XAI'nin amacı, araştırmacıların, geliştiricilerin, alan uzmanlarının ve kullanıcıların, yüksek performans ve doğruluklarını korurken makine öğrenimi modellerinin iç işleyişini daha iyi anlamalarına yardımcı olmaktır (Machlev ve ark., 2022).

Literatürde çeşitli XAI teknikleri bulunmaktadır (Adadi ve Berrada, 2018; Das ve Rad, 2020) ve bu tekniklerin çoğu derin öğrenme (DL-Deep Learning) modellerine odaklanmaktadır. Hsieh ve ark., (2021) ise çok değişkenli zaman serisi verilerinden açıklanabilir sınıflandırıcılar oluşturma problemini ele almayı amaçlamışlardır. Bu tür tahmin modellerini anlamak için kilit bir kriter, zaman içinde değişen girdi değişkenlerinin sınıflandırmaya katkısını aydınlatmak ve ölçmektir. Bu amaçla, sınıflandırıcı çıktısını belirleyen değişkenleri ve zaman aralıklarını eşzamanlı olarak tanımlayan yeni, modüler, konvolüsyon tabanlı bir özellik çıkarma ve dikkat mekanizması sunmuşlardır. Wang ve ark. (2019), tahmin sonuçlarını açıklamak için geliştirilmiş bir paralel xNN yöntemi sunmuştur. Özellikler ile sonuçlar arasındaki pozitif/negatif ilişki, öğrencilerin hangi bölümlerin iyileştirilmesi gerektiğini belirlemelerine yardımcı olabilir. Deneyler, iki gerçek çevrimiçi kurs verisi üzerinde gerçekleştirilmiş ve önerilen yaklaşımın bazı son teknoloji yöntemlerle karşılaştırıldığında olumlu performans gösterdiği saptanmıştır. Freeborough ve van Zyl (2022) tarafından uygulanan XAI yöntemleri, farklı mimarilerin tahmin etme biçimindeki önemli farklılıklara ilişkin paradigmaları destekleyen tamamlayıcı sonuçlar ortaya koymuştur. Açıklanabilirlik analizi, GRU'nun uzun vadeli bilgileri saklama konusunda en yüksek yeteneği sergilediğini, LSTM'nin ise girdi verilerinin çoğunu göz ardı edip dikkate aldığı verilere en ayrıntılı düzeyde odaklandığını göstermiştir. Öte yandan, yinelemeli (tekrarlayan) sinir ağlarının (Recurrent Neural Networks, RNN) uzun süreli hafıza tutma özelliği olmadığı gözlemlenmiştir. Gholami ve ark. (2023), arazi erozyon verilerine uygulanan RNN ve GRU modellerini DALEX (moDel Agnostic Language for Exploration and eXplanation) paketi aracılığıyla açıklamaya çalışmıştır. Duman (2023) ise çalışmasında açıklanabilir yapay zekâ yöntemlerini hayvancılık verileri üzerine uygulamıştır.

Birçok alanlarda olduğu gibi iktisadi değişkenler üzerine yapılan analizlerde de her bir bağımsız değişkenin bağımlı değişken üzerindeki etkisinin gücünü ve yönünü belirlemek oldukça önemlidir. Bu nedenle modellerin iç yapısını inceleyen algoritmaların geliştirilmesiyle, makine öğrenimi ve özellikle yapay zekâ yöntemlerinin veri analizlerinde önemi giderek artmaktadır.

Açıklanabilir yapay zekâ, makine öğrenimi metotları kullanılarak ulaşılmış olan en uygun modelin içeriğinin insanlar tarafından anlaşılabilir bir şekilde sunulması için kullanılan yöntem ve tekniklerdir (Özel, 2020). Bu yöntem vasıtasıyla veriye uygulanan makine öğrenimi metotlarındaki özniteliklerin (değişkenlerin) model ve çıktı üzerindeki etki boyutları ve yönü ortaya konulmaktadır. Diğer bir ifadeyle, açıklanabilir yapay zekâ metodu makine öğrenimi metotlarındaki karmaşık yapıyı ortaya koymaya olanak tanıyan bir metottur. Açıklanabilir yapay zekâ, yapay zekanın kör bir şekilde sebep-sonuç ilişkisi kurmadan bir tür ilahi güç gibi algılanmasını engelliyor (Kızrak, 2019). Bu çalışmanın amacı, tekrarlayan sinir ağları uygulamalı yapay zekâ yöntemleri vasıtasıyla yapılan tahminlerin ne kadar doğru olduğunu değerlendirmek ve yöntem hatalarını ölçmek, her bir bağımsız değişkenin bağımlı değişken üzerindeki etkisinin önemini belirlemektir. Bu amaca ulaşmak için Türkiye İstatistik Kurumundan (TÜİK), Hazine ve Maliye Bakanlığının Muhasebat Genel Müdürlüğünden elde edilen 2005:1– 2023:10 dönemini kapsayan aylık veriler ile Açıklayıcı Yapay Sinir Ağları metotlarının uygulanmıştır.

MATERYAL VE METOT

Veri Seti ve Model

Çalışmanın bu kısmında analizde kullanılan veri ve uygulanan model ele alınmıştır.

Çalışmada kullanılan göstergelerden istihdamla bağlı veriler Türkiye İstatistik Kurumundan diğer değişkenler Türkiye Cumhuriyeti Maliye Bakanlığından elde edilmiştir.


Çizelge 1. Kullanılan değişkenler

İ	Aylık istihdam değerleri
T	Bütçelerin aylık tahsilat verileri
G	Bütçe aylık harcamaları
O	Tahsilatın giderlere oranı

Model aşağıdaki gibidir.

$$I_t = \beta_0 + \beta_1 T_t + \beta_2 G_t + \beta_3 O_t + e_t \quad (1)$$

Şekil 1’de değişkenlerin grafiği yer almaktadır.



Şekil 1. Değişkenlerin Grafiksel Gösterimi

Johansen ve Juselius Testi

Eşbütünleşme, dikkate alınan değişkenler arasındaki ilişkinin, fark alma sırasında kaybolan ilgili uzun vadeli bilgilerinin geri alınmasını mümkün kılar. Yani, kısa vadeli dinamikleri uzun vadeli denge ile bütünleştirir. Bu, anlamlı bir tahmin ve politika uygulamasının itici gücü olan bir modelin gerçekçi

tahminlerini elde etmenin temelidir. Eşbütünleşme, farkı alındığında durağan olan serilerin ampirik olarak anlamlı ilişkilerini modellemek için tercih edilen bir adımdır. Eşbütünleşme, durağan olmayan zaman serisi verilerini kullanan herhangi bir ekonomik model için en önemli gereksinimlerinden biridir. Değişkenler eşbütünleşik değil ise, o zaman sahte regresyon problemi ortaya çıkabilmekte ve elde edilen sonuçlar anlamsız hale gelebilmektedir (Nkoro ve Uko, 2016).

Johansen ve Juselius Eşbütünleşme Testi (1990), eşbütünleşme vektörleri sayısını belirlemek için maksimum öz değer testi ve iz testi olmak üzere iki test kullanmaktadır. Hesaplama aşağıdaki gibidir:

$$LR_{max}\left(\frac{r}{n-1}\right) = -T * \log(1 - \lambda) \quad (2)$$

Burada λ , maksimum öz değer ve T, örneklem büyüklüğünü göstermektedir, bu test istatistikleri hipotezi aşağıdaki gibidir:

- $r(\pi) = 0$ ise eş bütünleşme yoktur; alternatif hipotez eş bütünleşme olduğu kabul edilir.
- $r(\pi) = n$ olduğunda eş bütünleşme ilişkisi sayı n'e eşittir; alternatif hipotez n'den büyüktür.

İz istatistikleri denklemi aşağıdaki formüle göre hesaplanır:

$$LR_{max}\left(\frac{r}{n}\right) = -T * \sum_{i=r+1}^n \log(1 - \hat{\lambda}_i) \quad (3)$$

Burada n, $r = 0, 1, 2 \dots n-1$ için denklemdaki değişkenlerin sayısını göstermektedir.

Bazı durumlarda iz ve maksimum öz değer istatistikleri farklı sonuçlar verebilir ve bu durumda iz testi sonuçlarının tercih edilmesi gerektiğini göstermek yararlı olabilir.

Vektör Hata Düzeltme Modeli (VECM)

Serilerin arasında eş bütünleşme ilişkisinin tespit edilmesi seriler arasında uzun dönemli bir denge ilişkisi olduğunu göstermektedir. Bu nedenle eş bütünleşik serilerin kısa dönem özelliklerinin değerlendirilmesinde VECM uygulanır. VECM için regresyon denklemi formu aşağıdaki gibidir:

$$\Delta Y_t = a_1 + p_1 e_1 + \sum_{i=0}^n \beta_i \Delta Y_{t-i} + \sum_{i=0}^n \delta_i \Delta X_{t-i} + \sum_{i=0}^n \gamma_i \Delta Z_{t-i} \quad (4)$$

$$\Delta X_t = a_2 + p_2 e_{t-1} + \sum_{i=0}^n \beta_i \Delta Y_{t-i} + \sum_{i=0}^n \delta_i \Delta X_{t-i} + \sum_{i=0}^n \gamma_i \Delta Z_{t-i} \quad (5)$$


VECM'de eş bütünleşme sıralaması, eş bütünleşme vektörlerinin sayısını gösterir. Örneğin, ikili bir sıra, durağan olmayan değişkenlerin doğrusal olarak bağımsız iki kombinasyonunun durağan olacağını gösterir. ECM'nin negatif ve anlamlı bir katsayısı (yani, yukarıdaki denklemlerde e_{t-1}), bağımsız değişkenler ile bağımlı değişken arasındaki herhangi bir kısa dönemli dalgalanmanın, değişkenler arasında istikrarlı bir uzun vadeli ilişkiye yol açacağını gösterir. Hata düzeltme modelini oluşturduktan sonra modelin varsayımlarını gözden geçirmek önemlidir.

GRU ve LSTM Uygulamaları

Modern makine öğrenimi yöntemleri, yüksek boyutlu ve çok değişkenli verilerle çalışabilirler ve genellikle üstün performans sunarlar. Bu yöntemler arasında yapay sinir ağları (YSA'lar) öne çıkar. YSA'lar yumuşak algılama ve öngörücü kontrol gibi birçok endüstriyel uygulamada kullanılmaktadır (Mateus ve ark., 2021). Yapay zekâ yöntemlerinin popülerliğindeki temel etkenlerden biri, klasik yöntemlere göre daha az varsayım gerektirmeleridir (Bnm, 2022). Bu nedenle, yapay zekâ yöntemleri zaman serileri tahmini ve diğer analitik işlemlerde giderek daha yaygın bir şekilde tercih edilmektedir.

RNN zaman serilerinde oldukça önemlidir. Bu yapı, zamanın önceki dönemlerini hatırlayarak şu anki verinin daha iyi anlaşılmasını sağlar. RNN, geçmiş bilgileri hatırlayabilme özelliği sayesinde zaman

serilerinde başarılı sonuçlar verir. Diğer derin öğrenme ağlarından farklı olarak, RNN bir önceki adımın çıkışını mevcut adımın girişi olarak kullanır. Bu özelliği sayesinde temel zaman serisi problemlerinde iyi sonuçlar elde eder (Hochreiter ve Schmidhuber, 1997).



Şekil 2. RNN, LSTM, GRU Mimarisi (Akköse 2020; Olah 2022; Yurtsever 2023)

Ancak, RNN'nin kısa vadeli bir hafızası olduğundan bazı problemlerde etkili olamayabilir. Örneğin uzun giriş verileriyle başa çıkamayabilir ve tahminde zorluk yaşayabilir. Ayrıca geriye yayılım sırasında gradyanın kaybolma problemi de yaşanabilir. Gradyan değerleri çok küçük olduğunda öğrenme sorunları ortaya çıkar, bu nedenlerden dolayı LSTM gibi RNN varyantları geliştirilmiştir (Akköse, 2020).

LSTM, bilgileri daha iyi depolayarak kısa vadeli bellek sorununu çözmek için tasarlanmıştır. Tüm RNN'ler, tekrar eden hücrelerden oluşan bir zincir şeklinde yapılandırılmıştır. Bu hücreler, ağı her bir zaman adımını temsil eder. Standart bir RNN tek bir Tanh katmanı içerirken, LSTM'ler iletişim halinde olan 4 farklı katman içerirler. LSTM, özelliklerin akışını ve kaybını kontrol etmek, RNN'lerin uzun vadeli bağımlılık sorununu çözmek, gradyan patlamasını ve RNN'nin kaybolmasını önlemek için bir kapı mekanizması sunar. LSTM, RNN'ler ile karşılaştırıldığında daha iyi uzun vadeli belleğe ve daha uzun zaman serisi işleme için daha iyi yeteneğe sahiptir (Wang ve Ying, 2023).

Her bir LSTM hücresi, kullanıldığında önemli bilgileri daha uzun süre tutabilir. Bu bilgi özelliği, LSTM'nin karmaşık dinamik dizileri sınıflandırmada, işlemede veya tahmin etmede iyi performans göstermesini sağlar. Bu özellikleri sayesinde LSTM, zaman serileri gibi uzun vadeli bağımlılık gerektiren problemlerde daha etkili bir şekilde kullanılabilir (Yeomans, 2019). Her LSTM hücresi kullanıldığında önemli bilgileri daha uzun süre muhafaza eder. Bu bilgi özelliği LSTM'nin karmaşık dinamiklerin sınıflandırılması, işlenmesi veya tahmin edilmesinde iyi performans göstermesini sağlar (Mateus ve ark., 2021).

LSTM modeli aşağıdaki gibi karakterize edilir (Yao ve ark., 2023):

Giriş kapısı (geçidi)

$$i_t = \sigma(W_i[h_{t-1}; x_t] + b_i) \quad (6)$$

Unutma Kapısı

$$f_t = \sigma(W_f[h_{t-1}; x_t] + b_f) \quad (7)$$

Çıkış Kapısı

$$o_t = \sigma(W_o[h_{t-1}; x_t] + b_o) \quad (8)$$

Hücre durumu

$$C'_t = \tanh(W_c[h_{t-1}; x_t] + b_c) \quad (9)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes C'_t \quad (10)$$

Çıkış vektörü

$$h_t = \tanh(C_t) \otimes o_t \quad (11)$$

$\otimes$ -skaler çarpımı (nokta çarpımı), h_{t-1} —önceki çıktı. C_{t-1} Önceki bellek durumudur, C'_t -aralık durumudur, x_t —girdi verisidir. W_i, W_f, W_o, W_c , ağırlık matrisini, b_i, b_f, b_o, b_c bias vektörlerini ifade

etmektedir. σ -standart bir sigmoid fonksiyonunu, tanh-hiperbolik tanjant aktivasyon fonksiyonunu ifade etmektedir.

LSTM'ler en popüler geçitli RNN'ler olmalarına rağmen, bu kadar sofistike bir geçit mekanizması aşırı karmaşık bir modelle sonuçlanabilir. Öte yandan, hesaplama verimliliği RNN'ler için çok önemli bir konudur ve son zamanlarda alternatif mimarilerin geliştirilmesi için önemli araştırma çabaları sarf edilmiştir, LSTM'leri basitleştirmeye yönelik kayda değer bir girişim, son zamanlarda sadece iki çarpımsal kapıya dayanan GRU adlı yeni bir modele yol açmıştır. Özellikle, standart GRU mimarisi aşağıdaki denklemlerle tanımlanır (Ravanelli ve ark., 2018):

$$z_t = \sigma(W_z x_t + U_z h_{t-1} + b_z) \quad (12)$$

$$r_t = \sigma(W_r x_t + U_r h_{t-1} + b_r) \quad (13)$$

$$h'_t = \tanh(W_h x_t + U_h (h_{t-1} \otimes r_t) + b_h) \quad (14)$$

$$h_t = z_t \otimes h_{t-1} (1 - z_t) \otimes h'_t \quad (15)$$

Burada z_t ve r_t sırasıyla güncelleme ve sıfırlama kapılarına karşılık gelen vektörlerdir, h_t ise mevcut t zaman dilimi için durum vektörünü temsil eder. Eleman bazında çarpımlar $\otimes$ ile gösterilir. $\sigma()$ ' her iki kapının aktivasyonları, z_t ve r_t 'yi 0 ile 1 arasında değişen değerler alacak şekilde kısıtlayan lojistik sigmoid fonksiyonlardır. W_z , W_r , W_h - ağırlık matrisini ve U_z , U_r , U_h tekrarlayan ağırlık matrislerini, x_t - ağ mevcut giriş vektörünü göstermektedir. Mimari son olarak, yanlılık vektörleri b_z , b_r ve b_h 'yi içermektedir.

Bazı mimariler, LSTM ve GRU ağırları ile tek değişkenli veya çok değişkenli zamansal serileri tahmin etmede iyi bir yeteneğe sahiptir (Mateus ve ark., 2021).

Evrişimli sinir ağı (CNN) modelinin ilk versiyonu, sinirbilim alanında kedilerin görsel sistemi üzerine yapılan çalışmalardan esinlenerek geliştirilen LeNet modelidir. Bu modelde, sinir ağına "alıcı alan" özelliği eklenmiş ve bu sayede konvolüsyonel katman oluşturulmuştur (Yang ve Wang, 2021). Günümüzde CNN modeli, hızlı eğitim süresi ve yüksek doğruluk oranları gibi özelliklere sahiptir. Temel işlevi, verilerden özellikler çıkarmaktır. Yapısı Şekil 3'te gösterilen bir konvolüsyonel katman, aktivasyon katmanı, havuzlama katmanı ve tam bağlantılı katmandan oluşmaktadır (Wang ve ark., 2021).



Şekil 3. 1D CNN Mimarisi

Konvolüsyonel katman, özelliklerin çıkarılmasında kritik rol oynar. Konvolüsyon çekirdeği, veri özelliklerinin belirlenmesinden sorumludur. Konvolüsyon çekirdeği sayısı arttıkça çıkarılan özellikler daha soyut hale gelir (Zhu ve ark. 2019). Her bir konvolüsyonel katmanın çıktısı, doğrusal olmayan ReLU fonksiyonu ile etkinleştirilir ve ardından bir sonraki konvolüsyonel katmana giriş olarak kabul edilir (Wang ve ark., 2021).

Havuzlama işlemi, maksimum havuzlama ve ortalama havuzlama olarak ikiye ayrılmaktadır. Tam bağlantılı katmanın görevi ise, havuzlama işlemi yapılmış nöronları tek boyutlu bir vektör haline genişletmek ve verilerin daha rahat işlenebilmesini sağlamaktır. Aktivasyon fonksiyonunun ana amacı, CNN'in bazı doğrusal olmayan verileri işleyebilme kapasitesini artırmak için konvolüsyonel katman tarafından çıkarılan özellikler üzerinde doğrusal olmayan bir eşleme işlemi gerçekleştirmektir. Yaygın olarak kullanılan aktivasyon fonksiyonları arasında ReLU, Lojistik Sigmoid ve Tanh fonksiyonları bulunmaktadır. Aktivasyon fonksiyonu, doğrusal olmayan problemleri çözmede yapının önemli bir parçası olup, özelliklerin korunması ve gereksiz verilerin elenmesi üzerinde büyük bir etkiye sahiptir. Fonksiyonel formları aşağıda verilmiştir:

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (16)$$

$$\tanh(x) = \frac{e^x - e^{-1}}{e^x + e^{-x}} \quad (17)$$

$$\text{ReLU}(x) = \max(0, x) \quad (18)$$

Araştırmamızda bu dört mimariyi oluşturmayı ve değerlendirmeyi hedefliyoruz. Model tanımı için GRU, LSTM, SimpleRNN ve 1D CNN ağlarını kullanacağız.

Bu çalışmada kullanılan 1D CNN ağı, sıralı veri özelliklerini çıkarmak için 2 konvolüsyonel katman ve maksimum havuzlama yöntemi kullanmaktadır. Yapısal olarak 1D CNN, konvolüsyonel katmanlar, havuzlama katmanları ve son olarak tam bağlantılı katman ile sonuçları çıkaran klasik CNN'e oldukça benzerdir. Kullanım açısından, CNN esas olarak iki boyutlu görüntü özelliklerini tanımak için kullanılırken, 1D CNN zaman serisi özelliklerinin tanınması ve çıkarılması amacıyla yaygın olarak tercih edilmektedir. 1D CNN yalnızca bir boyuta sahip olmasına rağmen, özellik tanıma konusunda CNN'in çeviri değişmezliği avantajını da sağlamaktadır. 1D CNN'de konvolüsyon çekirdeği tek boyutlu olduğundan, büyük bir çekirdek boyutu fazla parametre ve hesaplama yükü getirmez. Daha geniş bir alıcı alan elde etmek amacıyla model, dizinin özelliklerini daha kapsamlı bir şekilde yakalayabilmek için daha büyük bir konvolüsyon çekirdeği genişliği kullanabilir.

Giriş katmanında 200 nöron, ikinci gizli katmanda 300, üçüncü gizli katmanda 250, dördüncü gizli katmanda 200, beşinci gizli katmanda 100, altıncı gizli katmanda 35, yedinci gizli katmanda 20, sekizinci gizli katmanda 10, dokuzuncu gizli katmanda 5 ve çıkış katmanında 1 nöron olacak şekilde tanımlayacağız. Giriş şekli 7 özellik ile 1 zaman adımı olacaktır. Nöronların sayısını deneme yöntemiyle belirlemiştir.

Kayıp fonksiyonu olarak Ortalama Mutlak Hata (MAE) kullanacağız ve stokastik gradyan inişi için etkili olan Adam optimizasyon versiyonunu kullanacağız.

GRU, SimpleRNN, ve 1DCNN modeli için, 226 gözlemlili veri üzerinden 195'lik bir parti boyutu ile 50 eğitim epoku uygun görülmüştür. LSTM modeli için ise 226 gözlemlili veri üzerinden 195'lik bir parti boyutu ile 100 eğitim epoku uygun görülmüştür.

Son olarak, fit() fonksiyonunda validation_data argümanını ayarlanarak eğitim sırasında hem eğitim hem de test kaybı takip edilecektir.

Modellerin performansı, Kök Ortalama Hata Karesi (RMSE), ortalama mutlak hata (MAE), ortalama mutlak yüzde hata (MAPE), R^2 tahmini istatistiksel göstergeler kullanılarak değerlendirilmiştir. Bu istatistiksel verileri hesaplamak için Denklem 16, 17 ve 18 kullanılmaktadır.

$$RMSE = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n}} \quad (19)$$

$$MAE = \frac{\sum_{i=1}^n |e_i|}{n} \quad (20)$$

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{e_i}{y_i} \right|}{n} * 100 \quad (21)$$

n-gözlem sayısı, e_i -hata; y_i –gözlemleri göstermektedir.

BULGULAR VE TARTIŞMA

Zaman serisi analizlerinde uygulanacak klasik yöntemlerin belirlenmesinde durağanlık derecesi çok önemlidir. Bu analizi yapmak için öncelikle değişkenlerin durağan olup olmadıkları birim kök testi ile belirlenir. Değişkenler durağan değil ancak birinci farklarında durağan ise uzun dönem denge ilişkisi belirlenir. Değişkenler arasında eşbütünleşme ilişkisi varsa VECM tahmin edilerek kısa ve uzun dönem nedensellik sonuçları yorumlanır (Celik, 2015)

İlk aşamada verilerin durağanlık analizlerine bakılmıştır. Durağanlık analizlerinde Genişletilmiş Dickey ve Fuller (1979) (ADF) Testi uygulanmıştır.

ADF testi Python yazılım dilinin 3.11.5 versiyonunda, Statsmodels paketinin 0.14.0 versiyonunda yapılmıştır. Uygulanan teste ilişkin bulgular Çizelge 2’de verilmiştir.

Çizelge 2. Düzey ve Birinci Fark Değerlerinde ADF Test Sonuçları

	Düzey			Birinci Fark		
	Sabit Terimsiz ve Trendsiz	Sabit Terim	Sabit Terim ve Trend	Sabit Terimsiz ve Trendsiz	Sabit Terim	Sabit Terim ve Trend
Oran	-0.35[0,55]	-4.55[0,00]	-4.53[0,00]	-9.49[0,00]	-9.47[0,00]	-6.94[0,0]
Tahsilat	0.024[0,69]	-0.80[0,81]	-3.17 [0,089]	-5.99 [0,00]	-6.08 [0,00]	-6.22 [0,0]
Giderler	5.05 [0,1]	4.88 [0,1]	3.85 [0,1]	-13.20[0,00]	-13.39 [0,00]	-11.23[0,0]
İstihdam	4.61 [1,00]	0.43[0,03]	-1.31[0,88]	-4.80 [0,00]	-5.94 [0,00]	-5.95 [0,0]
Kritik Değerler						
%1	-2.65	-3.68	-4,33	-2.65	-3.69	-4.34
%5	1.95	-2.97	-3,58	- 1.95	-2.97	-3.59
%10	-1.60	-2.62	-3,23	-1.61	-2.63	-3.22

Not: köşeli parantez içindeki değerler olasılık değerlerini göstermektedir.

Çizelge 2’de sunulan ADF testi sonuçları incelendiğinde, düzey değerlerinde hiçbir değişkenin tam olarak %5 anlam düzeyinde durağan olmadığını, ancak tüm değerlerin birinci farkta %5 anlam düzeyinde durağan olduğu görülmektedir

Yukarıda gösterildiği gibi, birçok zaman serisi değişkeni yalnızca farkları alındıktan sonra durağandır. Regresyonlar için farkları alınmış serilerin kullanılması, ilgili uzun vadeli özelliklerin veya ele alınan değişkenler arasındaki denge ilişkisinin bilgisinin kaybı anlamına gelmektedir (Nkoro ve Uko, 2016).

Tüm değerler birinci farkta durağan olduğundan Johansen ve Juselius (1990) eşbütünleşme testi uygulanmıştır.

İlk etapta gecikme uzunluğu belirlenmelidir. Çizelge 3’te bu durum gösterilmiştir.

Çizelge 4’te (*) işareti Ardışık modifiye edilmiş son kestirim hatası FPE, Akaike (AIC), kriterinde dördüncü gecikme uzunluğunu uygun gecikme uzunluğu olduğunu işaret etmektedir.

Model için dördüncü gecikme uzunluğuna uygun Johansen eş bütünleşme testi sonuçları Çizelge 4’te verilmiştir.

Çizelge 3. VECM Modeli İçin Optimal Gecikme Uzunluğu

	AIC	BIC	FPE	HQIC
0	87.36	87.67*	8.738e+37	87.49
1	87.14	87.70	6.998e+37	87.37*
2	87.08	87.88	6.602e+37	87.41
3	87.10	88.15	6.701e+37	87.52
4	87.00*	88.29	6.077e+37*	87.52
5	87.07	88.61	6.542e+37	87.69

Not: * optimal gecikme uzunluğu

Çizelge 4. Johansen Eş Bütünleşme Testi

r_0	r_1	Test İstatistiği	Kritik Değerler
0	1	36.86	30.82
1	2	26.27	24.25
2	3	10.90	17.15

Çizelge 4'te görüleceği üzere iz istatistiğine göre birinci modelde değişkenler arasında 2 eş bütünleşme ilişkisi bulunmakta ve $H_1: r = 2$ Hipotezi reddedilememektedir.

Çizelge 5'te kalıntılarda otokorelasyonun varlığı ve model hatalarının dağılımının normallik varsayımlarını sınamak için kullanılan Portmanteau ve Jarque-Bera testi sonuçları yer almaktadır.

Çizelge 5. Normallik ve Otokorelasyon Testi

Testler	Test istatistiği	Kritik değerler	Olasılık değerleri	H0 hipotezi
1 Jarque-Bera testi	47498.448	15.507	0.00	Hataların dağılımı normaldir
2 Portmanteau testi	326.106	199.244	0.00	Kalıntıların 15 gecikmeye kadar otokorelasyon sıfırdır

Çizelgedeki bulgular H_0 hipotezinin reddedildiğini ve dolayısıyla modelin otokorelasyon içerdiğini ve normallik varsayımını ihlal ettiğini göstermektedir. Bu varsayımların ihlal edilmesi modelin tahminlerinin doğruluğunu azaltacaktır. Ancak bu varsayımların sağlanması için verilerin dönüştürülmesi gibi bazı yöntemler kullanılabilir (Sel, 2021). Ayrıca yukarıda da vurgu yaptığımız gibi her bir dönüştürme, verilerin ilgili değişkenleri ve onlar arasındaki gerçek etkileşimi temsil gücünü azaltabilir. Bu hususta yapay sinir ağları metotları önem kazanmaktadır. Bu metotlarda verilerin çok fazla dönüşüme tabi tutulmalarına gerek kalmamaktadır. Bu gibi sebeplerden de son zamanlarda makine öğrenimi yöntemlerinin popülerliği artmaktadır. Bu yöntemler, toplumları, politikaları, ekonomileri ve endüstrileri etkileyen veri analizi, örüntü tanıma ve tahmin araçları sunmaktadır.

Çizelge 6'da uygulanan modellerin performans değerleri verilmektedir.

Çizelge 6. GRU ve LSTM Eğitim ve Test Sonuçları

TESTLER	GRU	LSTM	CNN	RNN
Test RMSE	462.700	470.267	731.479	701.941
Train RMSE	481.143	484.420	690.532	529.607
Test MAE	369.078	358.914	542.699	550.564
Train MAE	401.216	390.846	551.277	432.746
Test MAPE	0.012120	0.011771	0.017556	0.017949
Train MAPE	0.017110	0.016573	0.023403	0.018096
Test R2	0.819390	0.813434	0.548614	0.584333
Train R2	0.978900	0.978612	0.956539	0.974435


Çizelge 6'dan GRU ve LSTM modellerinin performans değerlerinin, RNN ve CNN modellerine kıyasla daha iyi olduğu görülmektedir. RNN modelinin sonuçları da CNN modeline göre daha yüksek performans sergilemiştir. Bu bulgu, literatürde zaman serisi tahminlerinde LSTM ve GRU gibi RNN tabanlı yöntemlerin CNN modellerine göre daha iyi tahmin yapabileceğine dair hipotezleri desteklemektedir (Wang vd, 2021).

Çizelge 6'da olduğu gibi GRU modelinin test ve eğitim RMSE değerlerinin LSTM modelinin test ve eğitim RMSE değerlerinden daha düşük olduğu görülmektedir. Bundan farklı olarak LSTM modelinin MAE ve MAPE ve R^2 değerleri GRU modelinkinden daha düşüktür. Eğitim ve test değerleri arasındaki fark %10'dan fazla olsa da %20'den küçüktür. Bunun yanı sıra zaman serisi üzerine uygulanan makine öğrenimi metotlarında performans değerlendirmelerinde R^2 'den daha fazla hata değerleri, özellikle RMSE değeri göz önüne alınmaktadır (Hyndman., & Athanasopoulos, 2018).

Ayrıca, bağımsız değişkenin rakamsal büyüklüğünü göz önüne aldığımızda hem modellerin kıyaslanması açısından hem de test ve eğitim değerlerinin kıyaslanması açısından önemli bir farkın

olmadığı anlaşılmaktadır. MAPE değerlerine bakıldığında, bu sonucun daha net görüldüğünü söylenebilir.

Ayrıca trend ve test değerlerinin kıyaslanmasından varılan bu sonuç, zaman serisi analizlerinde çeşitli nedenlerle değişkenlerin tümünün veya bir kısmının trende sahip olmaları sonucunda ortaya çıkan sahte regresyonların oluşmadığını da göstermektedir.



Şekil 4. Eğitim Sürecinde Çok Değişkenli GRU (a) ve LSTM (b) Modelinin Kayıp Değerlerinin Grafiği

Analizler Python 3.11.15 sürümüyle gerçekleştirilmiştir. Araştırmada, Dalex kütüphanesinin 1.6.0 sürümü, Sklearn kütüphanesinin 1.3.0 sürümü ve Keras kütüphanesinin 2.12.0 sürümü kullanılmıştır.

Yukarıdaki grafiklerde GRU ve LSTM modellerinin MAE değeri üzerinden belirlenmiş test ve eğitim kayıp değerlerinin grafikleri görülmektedir (Şekil 4).


Şekil 4'den her iki modelin test ve eğitim kayıp değerlerinin birbirine yaklaşıyor azaldığını görmekteyiz. Bu durum modellerin genelleştirme yeteneğinin arttığını ve aşırı uyum (overfitting) olasılığının azaldığını gösterebilir.

Modellerin performans değerleri birbirine yakın olduğu için her iki model bazında açıklamalı yapay zekâ metotları uygulanmıştır. Bunun için DALEX paketinin olanakları kullanılmıştır (Baniecki ve ark., 2021). LSTM ve GRU mimarisi kendi yapıları gereği bağımsız değişkenlerin üç boyutlu olmasını talep etmektedir. DALEX paketinin girdileri ise iki boyutlu veriler şeklindedir. Bu sebepten literatürde LSTM ve GRU modellerinin sonuçlarına açıklanabilir yapay zekâ algoritmalarını içeren Dalex paketinin uygulanması pek rastlanmamaktadır. Makalenin analiz kısmında bu kopuklukları kendi geliştirdiğimiz kodlarla gidermeye çalıştık. Konuyla ilgili python kodları için github adresi aşağıdaki linkte verilmiştir.


<https://github.com/Polad81/DALEX-for-LSTM-GRU-model/blob/main/dalex%20according%20to%20lstm>

Açıklamalı yapay zekâ uygulamaları genel olarak Test veya Train değerlerine değil tüm veri üzerine uygulanmaktadır. Bunun için daha önce eğitilmiş ve test edilmiş veri bir bütün halde modele dahil edilmekte ve elde edilen sonuçlar bağımsız değişkenin tamamıyla kıyaslanmaktadır.

Şekil 5'ten de anlaşılabacağı gibi model üzerinde en büyük etkiye bağımsız değişkenin gecikmeli değeri sahiptir. Etki önemi bakımından ikinci sırada ise giderlerin gecikmeli değerleri gelmektedir. Diğer değişkenlerin etki önemleri oldukça küçük olmakla birlikte GRU ve LSTM modellerinde farklı sıralanmıştır. Bu farkı istihdam değişkeninin gecikmeli değerini dikkate almayan Şekil 6'da daha net görebiliriz.




Şekil 5. GRU (a) ve LSTM (b) modelinde Değişkenlerin Önem durumu



Şekil 6. GRU (a) ve LSTM (b) Modelinde İstihdam Değişkeni Çıkarılmış Değerlendirmede Değişkenlerin Önemi

Bu sıralamalar çok küçük değerlerle belirlendiği için üçüncü değişkenden itibaren GRU ve LSTM sonuçları arasındaki fark ihmal edilebilir düzeydedir. Bu durum, değişkenlerin gecikmeli ve cari değerlerini birlikte dikkate alan gruplaştırılmış etki grafiklerinde de görülmektedir.


Şekil 7’de her iki model için değişkenler üzerinden gruplaştırılmış etki grafikleri yansıtılmaktadır.



Şekil 7. GRU (a) ve LSTM (b) Modelinde Gruplandırılmış Değişkenlerin Önem Durumu


Durumu daha net görselleştirmek için Şekil 8’de istihdam değişkeni çıkarılmış değerlendirme yansıtılmıştır.

Görsellerden de anlaşıldığı üzere, genel olarak etkinin önemine göre ikinci sırayı bütçe giderleri, üçüncü sırayı bütçe tahsilatı, dördüncü sırayı ise tahsilatın giderlere olan oranı almaktadır. Bu grafikler, bağımsız değişkenlerin bağımlı değişken üzerindeki etkisinin yönünü değil, sadece önemini göstermektedir. Makine öğrenimi alanında, değişkenlerin etkisinin yönü ve modele bağlı birçok önemli ayrıntıyı göstermek için Dalex paketinin bize sunduğu açıklayıcı yapay zeka yöntemlerinden biri olan Kısmi Bağımlılık (Partial Dependence - PD) yöntemi kullanılmaktadır.



Şekil 8. İstihdam Değişkeni Çıkarılmış Değerlendirmede Değişkenlerin Önemi

PD profillerinin oluşturulmasının altında yatan genel fikir, model tahmininin beklenen değerinin seçilen bir açıklayıcı değişkenin fonksiyonu olarak nasıl davrandığını göstermektir. Tek bir model için, bir veri kümesindeki tüm gözlemler kullanılarak genel bir PD profili veya gözlemlerin alt grupları için birkaç profil oluşturulabilir. Alt gruplara özgü profillerin karşılaştırılması, örneğin modelin tahminlerinin istikrarına ilişkin önemli bilgiler sağlayabilir.



Şekil 9. GRU (a) ve LSTM (b) Modelinde Kısmi Bağımlılık Profili

Model tahmininin beklenen değerinin seçilen bir açıklayıcı değişkenin fonksiyonu olarak nasıl davrandığını göstermek için bir dizi bireysel Ceteris-Paribus (CP) profilinin ortalaması kullanılabilir. Bir CP profili örnek düzeyindeki bir tahminin açıklayıcı bir değişkene bağımlılığını göstermektedir. Bir PD profili, bir veri kümesindeki tüm örnekler (gözlemler) için CP profillerinin ortalaması ile tahmin edilir. Bir PD profili CP profillerinin üzerine çizilebilir. Birincisinin, ikincisini ne kadar iyi yakaladığını kontrol etmek için, bu, çok kullanışlı bir özelliktir (Biecek ve Burzykowski, 2021).

Şekil 8’de her bir bağımlı değişken için PD profili hesaplanmıştır. Eklemeli modeller için CP profilleri paraleldir. Özellikle, ortalama ve diğer değişkenler aynı şekle sahiptirler. Sonuç olarak, ortalamanın şekli diğerleriyle aynı olduğu için (şekli koruduğu için) modelin daha kesin bir tahmin ileri sürdüğünü göstermektedir. Profillerin paralel olması açıklayıcı değişkenlerin katkılarını ortaya koymaktadır. PD profilleri farklı modellerin karşılaştırılması için de faydalı olabilir. Tahmine dayalı

modellemedeki temel zorluklardan biri aşırı uyumdan kaçınmaktır. Bu konu, RNN modelleri gibi esnek modeller için özellikle önemlidir. Farklı modeller için profiller arasındaki uyum güven vericidir (Biecek ve Burzykowski, 2021). Şekil 8'deki grafiklerin birbirine benzemesi modelde aşırı uyumun olmamasına işaret etmektedir.

Değişkenler düzeyinde baktığımızda ise her iki modelde bağımlı ve bağımsız değişkenler arasında doğrusal bir ilişkinin olduğu anlaşılmaktadır. Özellikle bağımlı değişkenin gecikmeli değerinin daha etkin oldu görülmektedir. Bağımsız değişkenler içinde pozitif ilişkinin önemine göre ikinci sırada bütçe giderlerinin gecikmeli değeri gelmektedir. Bu, bütçe harcamalarının istihdam üzerine gecikmeli etki ettiğini göstermektedir. Dikkat çeken diğer bir önemli bulgu ise tahsilat değişkeninin mevcut değerinin istihdam üzerine olumlu etki etmesidir. Bununla beraber, tahsilat değişkeninin gecikmeli değerinin istihdam üzerine hafif olumsuz etki ettiği de görülmektedir.

Bunların dışında, tahsilatların giderlere oranlarının gecikmeli değerleri istihdam üzerine düşük düzeyde olumlu bir etkiye sahip olsa da cari değerlerinin istihdam üzerine hafif de olsa olumsuz etkisi görülmektedir. Tahsilat değişkeninin yukarıdaki etkisi göz önüne alındığında bu durumun daha çok bütçe harcamalarıyla bağlı olduğu kabul edilebilir. Başka bir deyişle, bu bulgu, bütçe açığını azaltıcı önlemlerin gecikmeli olarak olumlu etkilerini gösterirken, cari dönemde harcamaların kısılmasının olumsuz etkilerini yansıttığı şeklinde yorumlanabilir.

SONUÇ

Makine öğreniminde, her bir bağımsız değişkenin model ve dolayısıyla bağımlı değişken üzerindeki etkisinin gücünü ve yönünü belirlemek önemli bir rol oynamaktadır. Modellerin iç yapısını analiz eden algoritmaların geliştirilmesiyle birlikte, makine öğrenimi ve özellikle yapay zekâ yöntemlerinin sosyal bilimlerdeki kullanımı giderek artmaktadır. Bu tür yaklaşımlar, veri biliminde "açıklanabilir yapay zekâ" (Explainable AI - XAI) olarak adlandırılmaktadır.

Bu makalede, birinci farkta durağan olan ve doğrusal regresyon varsayımlarını karşılamayan verilere RNN (Recurrent Neural Network) yöntemleri uygulanmıştır. Performans açısından birbirine yakın sonuçlar veren iki RNN modeli (GRU ve LSTM), açıklamalı yapay zekâ metotları ile incelenmiştir. GRU modeli için RMSE değeri 462,7 iken, LSTM modeli için 470,3 olarak hesaplanmıştır. Bu nedenle her iki modelde de açıklamalı yapay zekâ metotları uygulanmıştır. Analiz için Dalex paketinin olanakları kullanılmıştır. LSTM ve GRU mimarilerinin üç boyutlu veri gereksinimi nedeniyle, Dalex paketinin iki boyutlu veri kabul eden yapısı, yazar tarafından geliştirilen özel kodlar ile uyarlanmıştır.

Açıklamalı yapay zekâ uygulamaları, genellikle yalnızca eğitim veya test verileriyle sınırlı kalmaz, tüm veri setine uygulanır. Bu çalışmada, daha önce eğitilen ve test edilen veri bir bütün olarak modele dâhil edilmiş ve elde edilen sonuçlar, bağımsız değişkenlerin tamamı ile kıyaslanmıştır. Üç boyutlu verilere uyarlanan Dalex paketinin sunduğu açıklayıcı yapay zekâ yöntemlerinden biri olan Kısmi Bağımlılık (Partial Dependence - PD) yöntemi kullanılarak elde edilen grafikler, yalnızca bağımsız değişkenlerin bağımlı değişken üzerindeki etkisinin düzeyini değil, aynı zamanda yönünü ve modele dair pek çok önemli detayı gözler önüne sermiştir.

Araştırma sonuçları, modelin bağımlı değişkeni olan istihdam üzerinde en büyük etkiyi sırasıyla bağımlı değişkenin gecikmeli değeri, bütçe giderleri ve bütçe tahsilatının gösterdiğini ortaya koymaktadır. En az etkili olan değişken ise bütçe tahsilatının bütçe giderlerine oranıdır. Bağımsız değişkenlerin etkisinin gücüne ve yönüne bakıldığında, en güçlü pozitif etki bağımlı değişkenin gecikmeli değerine aitken, bütçe giderlerinin gecikmeli değeri ikinci sırada yer almaktadır. Ayrıca, bütçe

gelirlerinin giderlere oranının gecikmeli değerinin düşük düzeyde olumlu, cari dönemde ise hafif olumsuz etkisi olduğu tespit edilmiştir.

Tahsilat değişkeninin gecikmeli değeri istihdam üzerinde hafif olumsuz bir etkiye sahipken, mevcut değeri istihdam üzerinde olumlu bir etkiye sahiptir. Benzer performans değerlerine sahip olan iki model üzerinde uygulanan açıklamalı yapay zekâ algoritmalarının sonuçlarının birbirine yakın olması, modellerin doğruluğu ve açıklayıcı algoritmaların pratikliğini göstermektedir.

Sonuç olarak, bazı veri kısıtları bulunsa da bu çalışma, parametrik varsayımların karşılanmadığı durumlarda bile açıklamalı yapay zekâ uygulamalarının iktisadi verilerde olduğu gibi farklı veri türlerinde de bağımsız değişkenlerin etkisini ve model içindeki önemini analiz edebileceğini göstermektedir.

Çıkar Çatışması

Makale tek yazarlı olup, yazar/yazarlar aralarında herhangi bir çıkar çatışması olmadığını beyan ederler.

KAYNAKLAR

- Adadi A, Berrada M. (2018). *Peeking inside the black-box: A survey on explainable artificial intelligence (XAI)*, in IEEE Access, vol. 6, pp. 52138-52160, doi: 10.1109/ACCESS.2018.2870052.
- Akköse, O. (2020, 22 Aralık). *Uzun-Kısa Vadeli Bellek (LSTM)*. 10.02.2024 tarihinde [https://medium.com/deep-learning-turkiye/uzun-k%C4%B1sa-vadeli-bellek-lstm-b018c07174a3#:~:text=Unutma%20Kap%C4%B1s%C4%B1\(Forget%20Gate\)%3A,State%20ile%20ta%C5%9F%C4%B1nmaya%20devam%20eder](https://medium.com/deep-learning-turkiye/uzun-k%C4%B1sa-vadeli-bellek-lstm-b018c07174a3#:~:text=Unutma%20Kap%C4%B1s%C4%B1(Forget%20Gate)%3A,State%20ile%20ta%C5%9F%C4%B1nmaya%20devam%20eder adresinden edinilmiştir) adresinden edinilmiştir.
- Angelov, P.P.; Soares, E.A.; Jiang, R.; Arnold, N.I.; Atkinson, P.M.(2021). *Explainable artificial intelligence: An analytical review*. Wiley Interdiscip. Rev. Data Min. Knowl. Discov. 11(5)
- Baniecki, H., Kretowicz, W., Piatyszek, P., Wiśniewski, J., & Biecek, P. (2021). *dalex: Responsible Machine Learning with Interactive Explainability and Fairness in Python*. Journal of Machine Learning Research, 22(214), 1–7. Retrieved from <http://jmlr.org/papers/v22/20-1473.html>
- Bnm, Manju (2022, 8 Haziran), *Non-Parametric Time Series Forecasting*. 10. 02 2024 tarihinde [https://manjubnm.medium.com/amazon-forecastsnon-parametric-time-series-forecasting-6ac8217acbd](https://manjubnm.medium.com/amazon-forecastsnon-parametric-time-series-forecasting-6ac8217acbd adresinden edinilmiştir) adresinden edinilmiştir
- Battaglini, M. ve Coate, S. (2011). *Fiscal Policy And Unemployment* (Working Paper No 17562). National Bureau Of Economic Research (Nber). <http://www.nber.org/papers/w17562> (14.02.2024)
- Biecek, P.& Burzykowski, T. (2021). *Explanatory Model Analysis, Explore, Explain, and Examine Predictive Models*. CRC Press
- Celik, Ş.(2015). Detection of Causal Relationship among Apricot Production, Dollar Exchange Rate and Gold Prices Using Co-integration Analysis and VECM: The Case of Turkey, International Journal of Science and Research (IJSR) , 5(7), 2056-2059., Doi: 10.21275/v5i7 Full Text Online (PDF) <https://www.ijsr.net/archive/v5i7/ART2016677.pdf>
- Das, A., & Rad, P. (2020). Opportunities and Challenges in Explainable Artificial Intelligence (XAI): A Survey. *ArXiv, abs/2006.11371*.
- Dickey, D. A. & Fuller, W. A. (1979). *Distribution of the Estimators for Autoregressive Time Series with a Unit Root*. Journal of the American Statistical Association, 74, 427-431. <https://doi.org/10.1080/01621459.1979.10482531>.
- Duman, H.(2023). Cevresel Koşulların Sığırlarda Sut Verimi Üzerine Etkisinin Makiine Öğrenme modelleri ile Araştırılması, Yayınlanmamış Doktora Tezi, Iğdır Üniversitesi, Iğdır.
- Ertop, K. (2006). *Makro İktisat*. Nihat Sayar Eğitim Vakfı Yayınları

- Freeborough, W.; van Zyl, T. (2022). Investigating Explainability Methods in Recurrent Neural Network Architectures for Financial Time Series Data. *Appl. Sci*, 12(3), 1427. <https://doi.org/10.3390/app12031427>
- Giordano, R., Momigliano, S., Neri, S. & Per, R. (2008). *The Effects Of Fiscal Policy In Italy: Evidence From A Var Model* [Working paper 656]. Banca D'Italia. https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1105745
- Gholami, H., Mohammadifar, A., Golzari, S. Song, Y., Pradhan, B. (2023). Interpretability of simple RNN and GRU deep learning models used to map land susceptibility to gully erosion, *Science of the Total Environment*, 904, 166960 <https://doi.org/10.1016/j.scitotenv.2023.166960>
- Gonzalo, J. 1994. Five Alternative Methods of Estimating Long-Run Equilibrium Relationships. *Journal of Econometrics*, 60, 203–233. [https://doi.org/10.1016/0304-4076\(94\)90044-2](https://doi.org/10.1016/0304-4076(94)90044-2).
- Caruana, R., Lou, Y., Gehrke, J., Koch, P., Sturm, M., Elhadad, N. (2015). Intelligible models for healthcare: Predicting pneumonia risk and hospital 30-day readmission. In *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Sydney, NSW, Australia, 10–13 August 2015; pp. 1721–1730.
- Gunning D, Stefik M, Choi J, Miller T, Stumpf S, Yang G-Z. (2019). *XAI-explainable artificial intelligence*. *Science Robotics*, 4(37).
- Johansen, S. and Juselius, K. (1990). Maximum Likelihood Estimation and Inference on Cointegration—With Applications to the Demand for Money. *Oxford Bulletin of Economics and Statistics*, 52, 169–210.
- Hsieh, T.-Y., Wang, S., Sun, Y., & Honavar, V. (2021). *Explainable multivariate time series classification: A deep neural network which learns to attend to important variables as well as informative time intervals*. In *Proceedings of the 14th ACM International Conference on Web Search and Data Mining* (pp. 607–615). Association for Computing Machinery. <https://doi.org/10.1145/3437963.3441815>
- Hochreiter, S. & Schmidhuber, J. (1997). Long short-term memory. *Neural Comput.*, 9 (8), 1735–1780
- Hyndman, R. J., & Athanasopoulos, G. (2018). *Forecasting: Principles and Practice* (2nd ed.). OTexts. <https://otexts.com/fpp2/>
- Kızrak, A. (2019). *Açıklanabilir Yapay Zekâ Nedir ve İhtiyaç Mıdır?* 14.02.2024 tarihinde <https://ayyucekizrak.medium.com/a%C3%A7%C4%B1kklanabilir-yapay-zeka-nedir-ve-i%C3%A7tiya%C3%A7-m%C4%B1d%C4%B1r-65adef9b086> adresinden edinilmiştir.
- Machlev, R., Heistrene, L., Perl, M., Levy, K.Y., Belikov, J., Mannor, S., Levron, Y. (2022). *Explainable Artificial Intelligence (XAI) techniques for energy and power systems: Review, challenges and opportunities*, *Energy and AI*, 9, <https://doi.org/10.1016/j.egyai.2022.100169>.
- Mateus, B. C. Mendes, M., Farinha, J. T., Assis, R. & Cardoso, A. M. (2021). Comparing Lstm And Gru Models To Predict The Condition Of A Pulp Paper Press, *Energies*, 14, 6958. <https://doi.org/10.3390/en14216958>
- Li, X. and Yang, T. (2021). Forecast of the Employment Situation of College Graduates Based on the LSTM Neural Network. *Hindawi Computational Intelligence and Neuroscience*, 1-11, <https://doi.org/10.1155/2021/5787355>
- Mulaudzi, R. 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, South Africa ISBN: 978-1-7281-9520-9
- Nkoro, E., Uko, A. K.(2016), Autoregressive Distributed Lag (ARDL) cointegration technique: application and interpretation. *Journal of Statistical and Econometric Methods*, 5(4), 63-91
- Ono, T. (2019). Growth, Unemployment, And Fiscal Policy: A Political Economy Analysis, *Macroeconomic Dynamics*, 23(8), 3099-3139

- Olah, C. (2022). *Understanding, L.S.T.M.: Networks*. [http:// colah. github. io/ posts/ 2015- 08- Under stand ingLS TMs/](http://colah.github.io/posts/2015-08-UnderstandingLSTMs/).
- Özel U. (2020). *Açıklanabilir Yapay Zekâ (Explainable AI)*. 12.02.2024 tarihinde <https://www.umutozel.com/explainable-ai> adresinden edinilmiştir.
- Parikh, R.B., Teeple, S.i Navathe, A.S.(2019). *Addressing bias in artificial intelligence in health care*. JAMA, 22(24):2377-2378, doi: 10.1001/jama.2019.18058
- Ravanelli, M. Brakel, P. Omologo, M. and Bengio, Y. (2018). Light Gated Recurrent Units for Speech Recognition. *IEEE Journal Of Emerging Topics In Computational Intelligence*, 2(2), 92-101
- Sel, A. (2020). *Python Uygulamalı İstatistik ve Veri Bilimi*. Akademisyen Kitap Evi yayınları
- TC Hazine ve Maliye Bakanlığı Muhasebat Genel Müdürlüğü 2023, <https://muhasebat.hmb.gov.tr/iller-itibariyle-merkezi-yonetim-butce-istatistikleri-2004-2019>
- Topal, M. H. (2017). Türkiye’de Kamu Yatırımlarının İstihdam Üzerindeki Etkisi: Bölgesel Bir Analiz (2004-2016). *Küresel İktisat ve İşletme Çalışmaları Dergisi*, 6(12), 186-204
- Türkiye İstatistik Kurumu (2022), Nüfusun İşgücü Durumu, Temel İşgücü Göstergeleri (15+ yaş) Tablosu, <https://data.tuik.gov.tr/Bulten/Index?p=İsgucu-Istatistikleri-Kasim-2022-49384>
- Kundu, S., Singhania, R. (2020). Forecasting the United States Unemployment Rate by Using Recurrent Neural Networks with Google Trends Data *International Journal of Trade, Economics and Finance*, 11 (6),
- Wang, M. & Ying, F. (2023). Point and interval prediction for significant wave height based on LSTM-GRU and KDE, *Ocean Engineering*, 289, 1-17
- Wang, K., Ma, C., Qiao, Y., Lu, X. Hao, W., Dong, S. (2021). A hybrid deep learning model with 1DCNN-LSTM-Attention networks for short-term traffic flow prediction, *Physica A: Statistical Mechanics and its Applications*, 583, 2021, ISSN 0378-4371, <https://doi.org/10.1016/j.physa.2021.126293>.
- Yeomans, J., Thwaites, S., Robertson, W.S., Booth, D., Ng, B. & Thewlis, D. (2019). Simulating Time-Series Data for Improved Deep Neural Network Performance. *IEEE*, 7, 131248–131255.
- Yurtsever, M. (2023). Unemployment rate forecasting: LSTM-GRU hybrid approach, *Journal for Labour Market Research*, 57(18). doi.org/10.1186/s12651-023-00345-8
- Yao, Z., Wang, Z., Wang, D., Wu, J. & Chen, L. (2023). An ensemble CNN-LSTM and GRU adaptive weighting model based improved sparrow search algorithm for predicting runoff using historical meteorological and runoff data as input. *Journal of Hydrology*, 625, 129977 7
- Zhu, J.H., Pei, J.H., Zhao, Y. (2019). *Research on convolution kernel initialization method in convolutional neural network (CNN) training*, *Signal Process.* 35 (4) (2019) 641–648.