

Yapay Sinir Ağları ve Derin Öğrenme Modeli Kullanılarak USD/TRY Döviz Kurunun Tahmin Edilmesi ¹

Ersin GÜMÜŞ ²

Başvuru Tarihi: 18.11.2022

Kabul Tarihi: 21.05.2024

Makale Türü: Araştırma Makalesi

Öz

Döviz kuru; hammadde, enerji, teknolojik ürünler gibi girdilerin maliyetlerini etkilemesi, dış borçların çevrilebilirliği, kurdaki oynaklıkların ekonomi üzerinde yaratacağı riskler gibi birçok nedenle en önemli ekonomik göstergelerden biridir. Çalışmada yapay sinir ağları ve derin öğrenme metoduyla USD/TRY döviz kurunun ay sonu değerlerinin, mevcut ay içerisinde veri açıklama takvimi doğrultusunda yayınlanan makroekonomik veriler üzerinden tahmin edilmesi amaçlanmıştır. 05:2006 – 08:2022 dönemini kapsayan aylık formatta hazırlanmış verilerin kullanıldığı çalışmanın ilk aşamasında veriler eğitim, doğrulama ve test setleri olarak ayrıştırılarak farklı katman ve nöron sayıları ile farklı derin öğrenme mimarileri denenmiş ve en uygun model tespit edilmiştir. İkinci aşamada Çapraz Doğrulama Yöntemi kullanılarak tespit edilen modelin tutarlılığı incelenmiş ve elde edilen bulgular sonucunda modelin tutarlılığına yönelik olumlu sonuçlara ulaşılmıştır. Son aşamada Eylül 2022 ve Ekim 2022 ay sonu USD/TRY döviz kurları, oluşturulan derin öğrenme modeli ile tahmin edilmiştir. Derin öğrenme modelinin belli hata sınırları içerisinde gerçek değerlere oldukça yakın tahmin değerleri üretebildiği, ayrıca kullanılan bağımsız değişkenlerin USD/TRY döviz kurunun ay sonu seviyesini tahmin etme gücüne sahip olduğu görülmüştür.

Anahtar Kelimeler: Döviz Kuru, Yapay Sinir Ağları, Derin Öğrenme, Çapraz Doğrulama

Atıf: Gümüş, E. (2024). Yapay sinir ağları ve derin öğrenme modeli kullanılarak USD/TRY döviz kurunun tahmin edilmesi. *Anadolu Üniversitesi Sosyal Bilimler Dergisi*, 24(2), 703-726.

¹ Bu çalışma etik kurul izin belgesi gerektirmemektedir.

² Bağımsız Araştırmacı, ersingm@gmail.com, ORCID: 0000-0001-5916-2686

Estimating USD/TRY Exchange Rate Using Artificial Neural Networks and Deep Learning Model

Ersin GÜMÜŞ³

Submitted by: 18.11.2022

Accepted by: 21.05.2024

Article Type: Research Article

Abstract

The exchange rate is one of the most important economic indicators for many reasons, such as affecting the costs of inputs such as raw materials, energy and technological products, the convertibility of external debt, and the risks posed by exchange rate volatility on the economy. In the study, it is aimed to predict the end-of-month values of the USD/TRY exchange rate through the macroeconomic data published in the current month in line with the data disclosure calendar, using artificial neural networks and deep learning method. In the first stage of this study, in which monthly data covering the period 05:2006 - 08:2022 were used, the data were separated as training, validation and test sets, and different deep learning architectures were tried with different layers and neuron numbers and the most suitable model was determined. In the second stage, the consistency of the determined model was examined by using the cross-validation method and as a result of the findings, positive results were obtained for the consistency of the model. At the last stage, USD/TRY exchange rates for September 2022 and October 2022 were estimated with the deep learning model. It has been observed that the deep learning model can produce prediction values that are very close to the real values within certain error limits, and that the independent variables used have the power to predict the end-of-month level of the USD/TRY exchange rate.

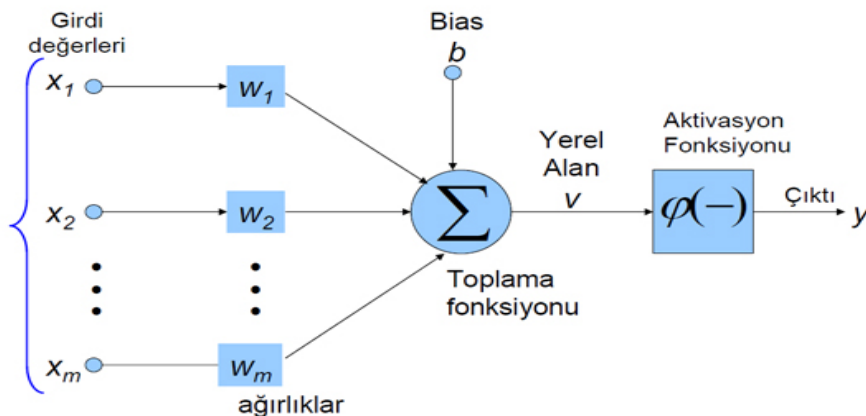
Keywords: Exchange Rate, Artificial Neural Networks, Deep Learning, Cross Validation

³ Independent Researcher, ersingm@gmail.com, ORCID: 0000-0001-5916-2686

Giriş

Yapay sinir ağları konusundaki ilk çalışma McCulloch ve Pitts'in (1943) sinirsel olaylar ve aralarındaki ilişkileri önerme mantığıyla ele alarak geliştirdikleri ilk modele dayanmaktadır. Rosentblatt (1957) tarafından tek katmanlı, eğitilebilen ve tek bir çıkışa sahip olan "perceptron" isimli yapay sinir ağının keşfinden sonra bu alandaki çalışmalar hız kazanmıştır. Uygulama alanındaki ilk önemli çalışma ise Widrow ve Hoff'un (1960) adaline (adaptive linear neuron) olarak adlandırdıkları ve geliştirdikleri modeldir. Bu çalışma sonraki çalışmalara da ışık tutmuştur. Ancak Minsky ve Papert (1969) XOR problemi çözümünü örnek göstererek yapay sinir ağlarının lineer olmayan problemlere yönelik çözüm üretmediğini öne sürmüştür, bu nedenle yapay sinir ağlarına yönelik çalışmaların bir değerinin de olmadığını ifade etmişlerdir. Bu süreç sonrasında, yavaşlamakla birlikte, Anderson (1972) ve Kohonen'in (1972) "çağrışımlı bellek" konusu üzerine gerçekleştirdiği benzer araştırmalar ile yapay sinir ağları üzerine çalışmalar devam etmiştir. Rumelhart, McClelland ve PDP Research Group (1986), ileri beslemeli modellerde yeni öğrenme modeli olan hatanın "Geriyeye Yayılma Algoritması" (Back Propagation Algorithm) geliştirmişlerdir. Çok katmanlı algılayıcıların da bulunmasıyla XOR problemi çözülmüş, yapay sinir ağlarına yönelik çalışmalar tekrar hız kazanmıştır. Bilgisayar ve yazılım teknolojilerinin de gelişimiyle süreç günümüze kadar ilerlemiştir. 1990'lı yıllardan günümüze kadar yapay sinir ağları ilk dönemlerin aksine teorik ve laboratuvar çalışmaları olmaktan ziyade, günlük hayatta kullanılan sistemlere entegre edilmeye ve yapılan uygulamalar ile birlikte pratik olarak insanlara yararlı olmaya başlamıştır (Öztemel, 2012).

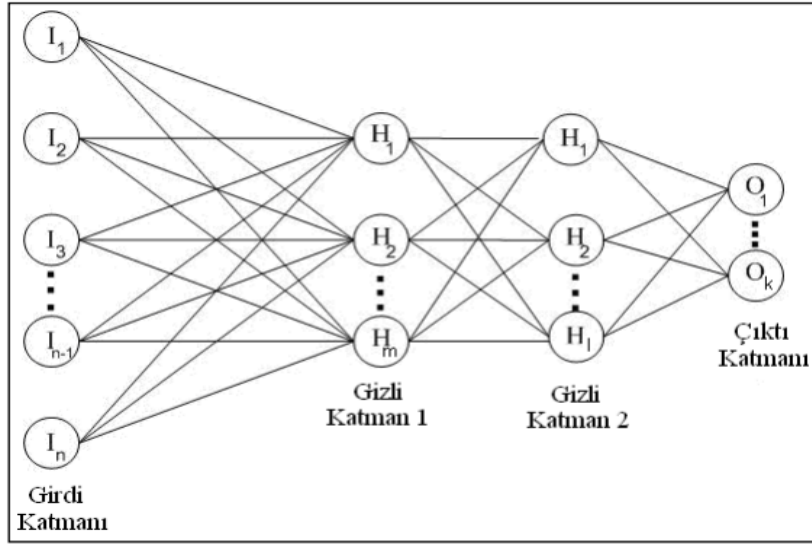
Yapay sinir ağı, en basit tanımıyla her bir nöronun bir işlem merkezini temsil ettiği ve bu işlem merkezlerinin (yapay nöronların) birbirine bağlı şekilde etkileşime girerek girdileri çıktıya dönüştürdüğü bir ağ olarak ifade edilebilir. Bu etkileşim sırasında her bir nöron aldığı girdiyi işlemden geçirerek sonraki nörona/nöronlara iletmektedir. Bu işlemler aktivasyon fonksiyonları adı verilen matematiksel fonksiyonlar kullanılarak gerçekleştirilir. Nöronlar arasındaki her bağlantı bir ağırlık (weight) ile ilişkilidir. Ağırlıklar bir yapay nörona gelen bilginin önemini ve nöron üzerindeki etkisini gösterir ancak ağırlıkların büyük ya da küçük olması önemli veya önemsiz olduğu anlamına gelmemektedir. Toplama fonksiyonu ile nörona gelen net girdi hesaplanır. Net girdi aktivasyon fonksiyonu kullanılarak ilgili nöronda çıktıya dönüşürken, bu çıktı diğer nöron/nöronlar için girdi olarak kullanılır. Şekil 1'de yapay bir nöronun yapısı görülmektedir.



Kaynak: Çınar (2018), <https://www.veribilimiokulu.com/yapay-sinir-aglari/>

Şekil 1. Yapay Nöron

Bir yapay sinir ağı mimarisinde ilk katman giriş katmanı, en son katman çıkış katmanı, aradaki tüm katmanlar ise gizli katman olarak adlandırılmaktadır. Şekil 2’de yapay sinir ağı mimarisi görülmektedir.



Kaynak: Çınar (2018), <https://www.veribilimiokulu.com/yapay-sinir-aglari/>

Şekil 2. Yapay Sinir Ağı Mimarisi

Derin öğrenme, yapay sinir ağları üzerine kurgulanmış bir tür makine öğrenimi yöntemidir. Derin öğrenme; yapay sinir ağlarının belirli algoritmalar kullanılarak eğitilmesi yöntemiyle hata oranlarının düşürülerek en başarılı çıktı sonuçlarını elde etmeye yönelik geliştirilen modeller olarak tanımlanabilir. Derin öğrenmede, kesin bir sayı belirtilmemekle birlikte çok katmanlı yapay sinir ağları kullanılmaktadır. Derin öğrenme günümüzde endüstri, tıp, robotik, bilgisayar görmesi, nesne tespiti, ses işleme-tanıma, çeviri, gelecek tahmini, finansal gibi pek çok alanda akıllı çözümler üretmektedir (Doğan ve Türkoğlu, 2019, s. 409).

Çalışmanın amacı, derin öğrenme metoduyla USD/TRY döviz kurunun ay sonu değerlerinin tahmin edilmesidir. Hammadde ve enerji gibi ana maliyet unsurlarının fiyatları üzerindeki etkisi açısından döviz kuru, hem kamu hem de özel sektör için en önemli göstergelerden biridir. Ayrıca döviz kurundaki değişimler, dış borç yükümlülükleri ve bu borçların sürdürülebilirliği açısından da önem arz etmektedir. Döviz kurundaki değişimler ise para politikası tercihleri, ödemeler dengesi, dış borç yapısı ve küresel etkenler (savaşlar, durgunluk, vb.) gibi birçok değişkene bağlıdır. Döviz kurunun en düşük hata oranlarıyla tahmin edilebilmesi karar vericilerin geleceğe yönelik daha doğru kararlar almasına olanak sağlayacaktır. Çalışmada, aylık olarak açıklanan ancak açıklandığı ay itibarıyla önceki aya/aylara ait değerleri yansıtan makroekonomik veriler, ilgili ay sonu USD/TRY döviz kurunun tahmininde kullanılmıştır. Çalışmanın odaklandığı temel nokta mevcut ay içerisinde veri açıklama takvimi doğrultusunda yayınlanan (bir önceki ay ve/veya iki ay öncesinin gerçekleşmeleri) makro veriler üzerinden ilgili ay sonu USD/TRY döviz kurunu tahmin etmektir. Böylece mevcut makro verilerin USD/TRY döviz kurunun hareketlerini açıklama gücü de incelenmiş olacaktır.

Çalışmada farklı katman ve nöron sayıları kullanılarak, farklı derin öğrenme mimarileri denenmiştir. İlk yöntemde veriler eğitim, doğrulama ve test verileri olarak ayrıştırılarak model eğitilmiş ve overfitting (aşırı öğrenme) sorunu oluşmaması için hata oranlarının tutarlılığı da göz önünde bulundurularak en düşük hata oranlarına ulaşılan mimari elde edilmiştir. İkinci yöntemde, ilk yöntemde elde edilen aynı mimari Çapraz

Doğrulama (Cross Validation) metoduyla tekrar denenmiş, böylece oluşturulan mimarinin başarısı yeniden gözden geçirilmiştir. Elde edilen model üzerinden tahminler gerçekleştirilerek, elde edilen bulgular incelenmiş ve sonuçlar yorumlanmıştır.

Literatür Taraması

Yapay sinir ağlarının finans alanında kullanımına yönelik geniş bir literatür bulunmakla birlikte, döviz kurlarının yapay sinir ağları aracılığıyla tahminine yönelik literatürün daha kısıtlı olduğu görülmektedir. Bu açıdan çalışmanın literatüre de ek katkı sağlayacağı düşünülmektedir. Konuya ilişkin literatür yurtdışı çalışmalar ve yurtiçi çalışmalar olarak iki kısımda ele alınmıştır.

Döviz kurlarının yapay sinir ağları ve derin öğrenme yöntemleriyle tahminine ilişkin yurtdışı literatür aşağıda özetlenmiştir.

Panda ve Narasimhan (2007), 6 Ocak 1994 – 10 Temmuz 2003 dönemini kapsayan haftalık Hint rupisi/ABD doları döviz kuru verilerini kullandıkları çalışmalarında, haftalık Hint rupisi/ABD doları döviz kurunun bir adım ileri tahminini yapmak için yapay sinir ağlarını kullanmışlardır. Sinir ağının tahmin doğruluğunu lineer otoregresif ve rastgele yürüyüş modelleri ile karşılaştırmışlardır. Altı tahmin değerlendirme kriteri kullandıkları çalışmada, sinir ağının lineer otoregresif ve rastgele yürüyüş modellerinden daha üstün örneklem içi tahmine sahip olduğunu görmüşler, döviz kurunu geleceğe yönelik tahmin etme olasılığının her zaman var olduğunu öne sürmüşlerdir.

Pradhan ve Kumar (2010) 1992-2009 yılları arasında Hindistan'daki döviz kurunu, ABD Doları, İngiliz Sterlini, Euro ve Japon Yeni'ne karşı iki tür veri seti (günlük ve aylık) kullanarak tahmin etmek için yapay sinir ağlarını (YSA) kullanmışlardır. Tahmin performansını, kök ortalama kareli hata (RMSE), ortalama mutlak hata (MAE), ortalama mutlak sapma (MAD) ve ortalama mutlak yüzde hata (MAPE) gibi çeşitli kayıp fonksiyonları kullanılarak ölçtükleri çalışmada, YSA'nın döviz kurunu tahmin etmede etkili bir araç olduğunu görmüşlerdir.

Kim, Lee, Kim ve Ahn (2018), 2012 – 2016 yılları arasındaki günlük verileri kullandıkları çalışmalarında, spot döviz kuru, Kore wonu faiz oranı, dolar faiz oranı ve dolar satın alma risk primini girdi değişkenleri olarak kullanmışlardır. Çalışmada USD/KRW döviz kurunu çok katmanlı algı modeli kullanarak tahmin etmişlerdir. Optimize edilmiş model yapısını bulmak için modeldeki gizli katmanların ve düğümlerin sayısını değiştirerek çeşitli denemeler yapmışlardır. Çalışmalarının sonucunda temsili bir yapay sinir ağı olan çok katmanlı algılayıcının, döviz kurunu tahmin etme yeteneğinin olduğunu görmüşlerdir.

Alizadeh, Rada, Balagh ve Esfahani (2020), USD/JPY döviz kurları tahmini için uyarlanabilir bir nöro-bulanık çıkarım sistemi (ANFIS) oluşturmuşlar, nöro-bulanık kural tabanlı sistemde bazı teknik ve temel indeksleri girdi değişkenleri olarak kullanmışlardır. Ocak 2001'den Ağustos 2008'e günlük verilerin kullanıldığı çalışmada, nöro-bulanık model 28 aday girdi değişkeni ile test edilmiştir. Karşılaştırma amacıyla, ileri beslemeli çok katmanlı sinir ağı ve çoklu regresyon gibi yöntemlerle kıyaslama yapmışlar, kendi sundukları algoritmanın tahmin hatası minimizasyonu, sağlamlık ve esneklik açısından üstünlük gösterdiğini tespit etmişlerdir.

Li, Pan ve Wang (2020) ABD Doları-Çin Yuanı (USD-CNY) döviz kurunun trendini tahmin etmek için geri yayılım (BP) sinir ağı modeli kullanmışlardır. Çalışmanın sonucunda USD-CNY'nin son yıllarda düşüş trendi gösterdiği tespit edilmiştir. Ayrıca USD-CNY kurunu etkileyen faktörler analiz edilmiş, ödemeler dengesi, emtia fiyatları ile USD-CNY arasında negatif korelasyon olduğu; enflasyon oranı, gayri safi yurtiçi hasıla (GSYİH), döviz rezervleri ile USD-CNY arasında ise pozitif korelasyon olduğu görülmüştür.

Urrutia, Bariga ve Putong (2021) çalışmalarında, çoklu doğrusal regresyon ve çok katmanlı ileri beslemeli sinir ağı kullanarak Kasım 2018'den Aralık 2023'e kadar Filipinler'in aylık döviz kuru (Peso-Dollar) tahminini gerçekleştirmişlerdir. Enflasyon oranı, ödemeler dengesi, faiz oranı, üretici fiyat endeksi, ihracat, ithalat ve para

arzu değişkenlerinin Ocak 2007'den Ekim 2018'e kadarki verileri ile çoklu doğrusal regresyon modeli kullanarak bağımsız değişkenler arasındaki döviz kuruna etki eden önemli tahmincileri belirlemiştir. Regresyon analizi sonucunda sadece iki bağımsız değişkenin (ödemeler dengesi ve ithalat) önemli tahminciler olduğu kanaatine varılmıştır. Bu değişkenler kullanılarak Kasım 2018 - Aralık 2023 dönemi için hem çoklu regresyon modeli hem de çok katmanlı ileri beslemeli sinir ağı modeli ile döviz kuru tahminleri yapılmış, çok katmanlı ileri beslemeli sinir ağının Filipinler'deki döviz kurunu tahmin etmek için en uygun model olduğu sonucuna varılmıştır.

Yapay sinir ağları ve derin öğrenme yöntemleriyle döviz kurlarının tahminine ilişkin yurtiçi literatür ise aşağıda sunulmuştur.

Özkan (2011) yapay sinir ağları ile döviz kuru tahmininde alternatif çözüm yöntemlerinin geliştirilmesi amacıyla yaptığı çalışmada, döviz kuru öngörüsünde kullanılan zaman serisi modellerindeki "gecikmeli değerler" ve döviz kuru öngörüsünde kullanılan yapısal modellerden "Parasal Model ve Satınalma Gücü Paritesi modellerinin değişkenlerini" kullanarak oluşturulan yapay sinir ağları modellerinin tahmin performanslarını incelemiştir. ABD Doları için 1986-2010 dönemi, Euro için 1999-2010 dönemi verileri kullanılmıştır. Döviz kurlarının (ABD Doları ve Euro) tahmininde; birinci yöntemde girdi verileri olarak gecikmeli döviz kuru verilerini; ikinci yöntemde girdi verileri olarak Türkiye ve yabancı ülkelerin (ABD Doları için ABD, Euro için Avrupa bölgesi) tüketici fiyat endeksi verilerini; üçüncü yöntemde ise girdi verileri olarak Türkiye ve yabancı ülkelerin enflasyon, para arzı (M1), faiz ve milli gelir verilerini kullanmıştır. Çalışma sonucunda döviz kuru değişkeninin gecikmeli değerleri kullanılarak oluşturulan yapay sinir ağları modelinin en iyi öngörü gücüne sahip olduğu görülmüştür.

Özkan (2012) bir diğer çalışmada, yapay sinir ağı modelleri ile yerli ve yabancı ülkelere ait enflasyon, para arzı, faiz oranı ve milli gelir ekonomik verilerini kullanarak, Amerikan Doları ve Euro döviz kurlarını tahmin etmiştir. ABD Doları için yabancı ülke verileri olarak Amerika Birleşik Devletleri, Euro için yabancı ülke verileri olarak Avrupa Birliği, yerli ülke verileri olarak da Türkiye verileri kullanılmıştır. ABD doları için 1986-2010, Euro için ise 1999-2010 döneminin ele alındığı çalışmada YSA'nın yüksek tahmin gücüne ulaştığı görülmüştür.

Bal ve Demir (2017) çalışmalarında, Ocak 1999 – Ekim 2016 dönemi haftalık verilerini kullanarak USD/EUR, USD/GBP, USD/JPY ve USD/NOK döviz kurlarını farklı öğrenme algoritmaları, aktivasyon fonksiyonları ve performans ölçülerinin kullanıldığı yapay sinir ağı modelleri ile tahmin etmişlerdir. Döviz kuru tahmininde yapay sinir ağı modellemesi için uygun parametre kombinasyonuna karar vermede deneme yanılma yönteminin kullanılmasının uygun olacağını öne sürmüşlerdir.

Mohammadi (2019) geri yayılım (backpropagation), radyal temel fonksiyon (RBF), uzun kısa süreli bellek ve destek vektör regresyonu (SVR) şeklinde dört makine öğrenimi modeli kullanarak EUR/USD, USD/JPY ve USD/TRY döviz kurlarını tahmin etmiştir. EUR/USD ve USD/JPY döviz kurları için 01.01.2005 – 01.09.2018 tarihleri arası, USD/TRY döviz kuru için 13.03.2007 – 01.09.2018 tarihleri arası; açılış değeri, kapanış değeri, en düşük değer, en yüksek değer ve işlem hacmine ilişkin günlük veriler kullanılmış, analizler sonucunda destek vektör regresyonunun (SVR) diğer üç teknikten daha iyi performans gösterdiği ve geri yayılımın en az performans gösterdiği sonucuna ulaşılmıştır.

Çuhadar, Demirbaş ve Dayan (2019) gerçekleştirdikleri çalışmada, TÜFE bazlı Reel Efektif Döviz Kurunu tahmin etmek amacıyla farklı mimarilere sahip yapay sinir ağı modelleri ile Box-Jenkins ve Üstel Düzleştirme Yöntemlerini kullanmışlardır. Ocak 2003 – Mart 2019 dönemini kapsayan 195 aylık TÜFE bazlı Reel Efektif Döviz Kuru verilerinin kullanıldığı çalışmada tahmin başarıları ortalama mutlak yüzde hata istatistiği ile değerlendirilmiştir. Tahmin başarılarını karşılaştırarak en yüksek tahmin performansı gösteren modeli

belirlemiş ve belirlenen model yardımıyla 2019 yılı için aylık TÜFE bazlı Reel Efektif Döviz Kuru tahminlerini üretmişlerdir. Modeller arasında en başarılı sonucu veren modelin, Box-Jenkins Çarpımsal-Mevsimsel ARIMA modeli olduğu görülmüştür.

Bu çalışmada, literatürde yer alan çalışmalarda kullanılan bazı makroekonomik değişkenlerin yanında Net Hata ve Noksan Hesabı değişkeni de kullanılmıştır. Çalışmanın diğer çalışmalardan ayrılan en belirgin özelliği ise derin öğrenme mimarisi başarısının Çapraz Doğrulama Yöntemi kullanılarak tekrar değerlendirilmesidir. Çalışma, bu açıdan derin öğrenme metodu ile Türkiye'de döviz kurlarının tahmin edilmesinde Çapraz Doğrulama Yöntemi kullanılarak model tutarlılığının analizine ilişkin yeni bir katkı sağlamaktadır.

Metodoloji ve Veri Seti

Çalışmada, TCMB Elektronik Veri Dağıtım Sistemi üzerinden yayınlanan USD/TRY döviz alış kurunun aylık verileri bağımlı değişken olarak kullanılırken; Cari İşlemler Hesabı (yıllıklandırılmış), TÜFE Farkı, Brüt Döviz Rezervleri, Kısa Vadeli Dış Borç Stoku, İki Yıllık Tahvil Faizleri Farkı, Net Hata ve Noksan Hesabı (yıllıklandırılmış) ve Para Arzının (M1) aylık bazda verileri bağımsız değişkenler olarak belirlenmiştir. Cari İşlemler Hesabı, Brüt Döviz Rezervleri, Kısa Vadeli Dış Borç Stoku, Para Arzı (M1) ve Net Hata ve Noksan Hesabı verileri TCMB Elektronik Veri Dağıtım Sisteminden; Türkiye Tüfe verileri TCMB istatistikler sayfasından; ABD Tüfe, Türkiye İki Yıllık Tahvil Faizi ve ABD İki Yıllık Tahvil Faizi verileri “<https://tr.investing.com/>” adresinden temin edilmiştir. TÜFE Farkı ve İki Yıllık Tahvil Faizleri Farkı değişkenleri, gerçekleşme açısından aynı dönemlere denk gelen ABD ve Türkiye verilerinin farkını ifade etmektedir. Bağımsız değişkenler veri açıklama takvimine uygun olarak önceki ayın veya iki ay öncesinin gerçekleşmelerini göstermektedir. Ayrıca geçmiş dönem etkilerini de dikkate alabilmek için, bütün bağımsız değişkenlerin bir ay gecikmeli verileri de modele dâhil edilerek USD/TRY döviz kurunun tahmininde toplam 14 bağımsız değişken belirlenmiştir. Brüt Döviz Rezervleri, İki Yıllık Tahvil Faizleri ve M1 Para Arzı değişkenlerinin veri açıklama süreçleri daha güncel olup, dönem uyumu açısından bu değişkenlerin de bir ay önceki ay sonu verileri baz alınmıştır. Oluşturulan veri seti 05:2006 – 08:2022 dönemini (196 ay) kapsamaktadır. Tablo 1’de değişkenlere ilişkin açıklayıcı bilgiler sunulmuştur.

Tablo 1
Değişkenlere İlişkin Açıklayıcı Bilgiler

Değişkenler	Açıklanma Periyodu	Açıklanma Dönemi	Gerçekleşme Dönemi	Modellerde Kullanılan Dönemler
USD/TRY	Günlük	Günlük	Günlük	İlgili ay sonu gerçekleşmesi
Cari İşlemler Hesabı	Aylık	Yayımlama takvimi kamuoyuna önceden duyurulmaktadır. Uygulamada ilgili ayın 2. haftası	2 ay öncesinin gerçekleşmesi	2 ay önce ve 3 ay öncesinin gerçekleşmeleri
Tüfe Farkı	Aylık	Türkiye için (Tüfe) ilgili ayın ilk haftası, ABD için (Tüfe) ilgili ayın 2. haftası	1 ay öncesinin gerçekleşmesi	1 ay önce ve 2 ay öncesinin gerçekleşmeleri
Brüt Döviz Rezervleri	Aylık, Haftalık	İlgili ay, ilgili hafta	Önceki ay, Önceki hafta	1 ay öncesinin ve 2 ay öncesinin ay sonu değerleri
Kısa Vadeli Dış Borç Stoku	Aylık	Yayımlama takvimi kamuoyuna önceden duyurulmaktadır. Uygulamada genellikle ilgili ayın 3. haftası	2 ay öncesinin gerçekleşmesi	2 ay önce ve 3 ay öncesinin gerçekleşmeleri
İki Yıllık Tahvil Faizleri Farkı	Günlük	Günlük (Türkiye ve ABD için)	Günlük	1 ay öncesinin ve 2 ay öncesinin ay sonu değerleri
Net Hata ve Noksan Hesabı	Aylık	Yayımlama takvimi kamuoyuna önceden duyurulmaktadır. Uygulamada ilgili ayın 2. haftası	2 ay öncesinin gerçekleşmesi	2 ay önce ve 3 ay öncesinin gerçekleşmeleri
Para Arzı (M1)	Haftalık	Haftalık	Önceki hafta	1 ay öncesinin ve 2 ay öncesinin ay sonu değerleri

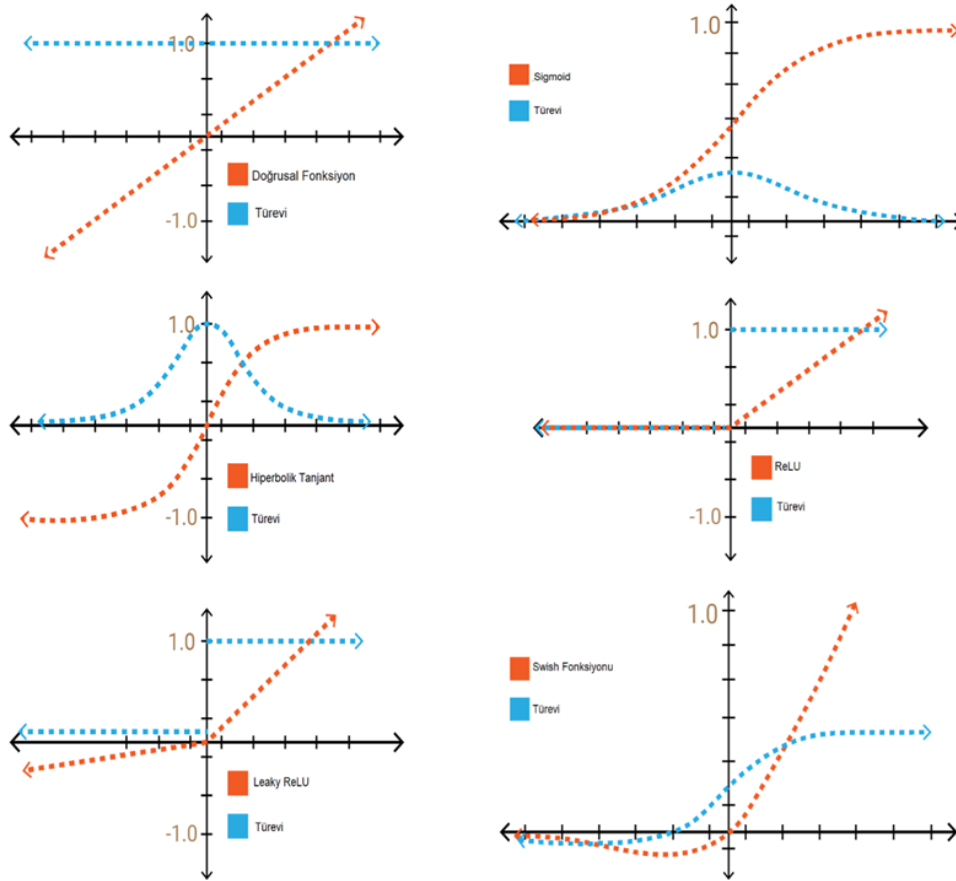
USD/TRY döviz kurunu tahmin etmek üzere yapay sinir ağı mimarilerinin geliştirilmesi ve derin öğrenme metodunun uygulanmasında Python kullanılmıştır. Numpy, Matplotlib, Pandas, Sklearn, Tensorflow, Keras ve KFold kütüphaneleri kullanılarak gerekli kodlar oluşturulmuştur. Tabloların ve bazı grafiklerin oluşturulmasında Excel programından da yararlanılmıştır. Çalışmada iki ayrı yöntem uygulanmıştır. İlk yöntemde çeşitli mimariler oluşturularak farklı modeller denenmiş ve tahmin açısından en uygun mimari tespit edilmeye çalışılmıştır. En uygun modelin tespit edilmesinden sonra, ikinci yöntemde Çapraz Doğrulama metodu uygulanarak ilk yöntemde elde edilen mimarinin başarısı tekrar değerlendirilmiştir. Son aşamada elde edilen modellerle güncel veriler üzerinden USD/TRY döviz kuru tahminleri yapılmış ve sonuçlar incelenmiştir.

Yöntem

Derin öğrenme metodunun uygulanmasında ilk aşama ölçeklendirme yöntemi, aktivasyon fonksiyonları, kayıp (hata) fonksiyonları ve öğrenme algoritmalarının belirlenmesidir.

Özellik ölçeklendirme (feature scaling) ile değişkenler derin öğrenme algoritmalarına sokulmadan önce belirli aralıklara indirgenmektedir. Burada amaç rakamsal veriler arasındaki büyüklüklerin çok fazla olduğu durumlarda verileri daha küçük bir aralığa yerleştirmektir. Yapay sinir ağlarının eğitimi, ham veri setine Normalizasyon (Ölçeklendirme) Yöntemi uygulanmadan çok yavaş olabilir. Aşırı büyük ve küçük değerler, net girdinin hesaplanmasında aşırı büyük veya küçük değerlerin doğmasına neden olarak ağı yanlış

yönlendirebilirler (Yavuz ve Devenci, 2012, s. 175). Derin öğrenme metodunda, bütün verilerin ölçeklendirilmesi ile tüm girdiler aynı ölçek üzerine indirgenirken, aynı zamanda yanlış yönlendirme sebebiyle oluşabilecek çok büyük ve/veya küçük değerlerin etkisi de ortadan kaldırılmış olur. Uygulamada Standart Ölçeklendirme (Standard Scaling), Robust Ölçeklendirme (Robust Scaling), MaxAbs Ölçeklendirme (MaxAbs Scaling), MinMax Ölçeklendirme (MinMax Scaling) gibi ölçeklendirme yöntemleri kullanılmaktadır. Standart Ölçeklendirme (Standard Scaling) ortalama değerin 0, standart sapmanın 1 değerini aldığı, dağılımı normal dağılıma yaklaştıran bir yöntemdir. MinMax Ölçeklendirme (MinMax Scaling) verinin 0 ile 1 arasında değerler aldığı bir normalleştirme yöntemidir ve bu yöntemde 'outlier' denilen aykırı verilere karşı hassasiyet durumu da mevcuttur. MinMax Ölçeklendirme Yönteminde verilerin dağılımı farklı aralıklara da ayarlanabilmektedir. Robust Ölçeklendirme (Robust Scaling) Yöntemi Normalizasyon Yöntemi ile benzer olup, bu yöntemde aykırı değerler dışarıda bırakılmaktadır. MaxAbs Ölçeklendirmede (MaxAbs Scaling) ise her özelliğin maksimum mutlak değeri 1 olacak şekilde her özellik ayrı ayrı ölçeklendirilir ve dönüştürülür. Ölçeklendirmede hangi yöntemin seçileceğine yönelik belirli bir standart bulunmamaktadır. Veri seti ve model yapısına göre modeli tasarlayanlar tarafından uygun bir yöntem belirlenmektedir.



Kaynak: Kızrak (2019), <https://ayyucekizrak.medium.com>

Şekil 3. Aktivasyon Fonksiyonları ve Türevleri

Aktivasyon fonksiyonları nörona gelen bilgilerin toplama fonksiyonu ile birleştirilmesinden sonra oluşan net girdinin nasıl bir işlemde geçireceğini belirleyen fonksiyonlardır. Genellikle doğrusal olmayan bu fonksiyonlar ile yapay sinir ağı modelleri veri içerisindeki karmaşık yapıları daha iyi öğrenip başarılı sonuçlar oluşturur. Uygulamada birçok farklı aktivasyon fonksiyonu kullanılmakla birlikte, her birinin diğerlerine göre pozitif ve negatif yönleri bulunmaktadır. Şekil 3'te en çok kullanılan aktivasyon fonksiyonlarının grafikleri sunulmuştur.

Derin öğrenmede, öğrenme süreci geriye yayılım algoritması ile gerçekleşmektedir. Bu algoritmalarda türev alan bir süreç uygulanmakta olup, temel amaç ağırlıkları güncelleyerek, üretilen çıktılarda hedef çıktıya daha yakın sonuçlar elde etmektir.

$$w_{t+1} = w_t - \alpha \frac{\partial L}{\partial w_t} \quad (1)$$

Eşitlik 1'de en temel algoritma olan SGD'nin (Stokastik Gradyan İniş) formülü gösterilmektedir. Burada gradyan ($\partial L/\partial w_t$), öğrenme katsayısı (α) ile çarpılır ve mevcut ağırlık bir önceki ağırlığa göre güncellenir. Gradyan iniş algoritmaları ile hata fonksiyonu en aza indirilerek minimum hataya ulaşılmaya çalışılır. Hata fonksiyonları ise tahmin edilen değer ile gerçek değer arasındaki farkı ortaya koyan fonksiyonlardır. Eğitim esnasında hata değerlerinin sıfıra yaklaşması beklenmektedir.

Eşitlik 2'de doğrusal fonksiyon görülmektedir. Doğrusal fonksiyonda türevin sabit olması öğrenme işleminin gerçekleşmediğini göstermektedir. Tüm katmanlarda doğrusal fonksiyon kullanılması, giriş katmanı ile çıkış katmanı arasında hep aynı doğrusal sonuçlara ulaşılması sonucunu doğurur. Bu nedenle aktivasyon fonksiyonları olarak karmaşık yapıların öğrenilebilmesi için doğrusal olmayan fonksiyonlar kullanılır.

$$\text{Doğrusal}(x) = a \cdot x \quad (2)$$

Eşitlik 3'te sigmoid fonksiyon formülü yer almaktadır. Sigmoid fonksiyonlar türevi alınabilir olduğu için çok sık kullanılmakla beraber, bu fonksiyonun uçlarında türev değerleri çok küçülerek sıfıra yaklaşmaktadır. Uç noktalarda y değerleri x değerlerindeki değişikliklere çok az tepki verir.

$$\text{Sigmoid}(x) = \frac{1}{1+e^{-x}} \quad (3)$$

Eşitlik 4'te hiperbolik tanjant fonksiyonu görülmektedir. Hiperbolik tanjant fonksiyonunda türev daha dik olduğu için daha çok değer alacaktır. Türev daha çok değer alacağı için bu fonksiyonun daha verimli olacağı söylenebilir. Ancak yine fonksiyonun uçlarında sigmoid fonksiyondakine benzer problemler görülecektir.

$$\text{Hiperbolik Tanjant}(x) = \frac{1-e^{-2x}}{1+e^{-2x}} \quad (4)$$

Eşitlik 5'te yer alan ReLU (Rectifier Linear Unit) fonksiyonu 0 ve $+\infty$ arasında değer almaktadır. Bu fonksiyonun ana avantajı bir nöron negatif değer üretirse aktive edilmeyeceği için, tüm nöronların aynı anda aktive olmamasıdır. Böylece oluşturulan ağ daha hızlı çalışmaktadır. Ancak bu fonksiyonda 0 değer bölgesi işlem hızı kazandırmakla birlikte bu bölgenin türevi de 0 olmakta ve bu bölgede öğrenme gerçekleşmemektedir.

$$\text{ReLU}(x) = \begin{cases} 0 & \text{eğer } x < 0; \\ x & \text{eğer } x \geq 0 \end{cases} \quad (5)$$

Eşitlik 6'da görülen Leaky ReLU fonksiyonunda ise tanım aralığı $-\infty$ 'a doğru devam etmektedir. Böylece 0'a yakın ama 0 olmayan bu değerler sayesinde ReLU fonksiyonunda yok olan değerler kurtarılmış ve öğrenme negatif bölgedeki değerler için de sağlanmış olur.

$$\text{Leaky ReLU}(x) = \begin{cases} 0.01x & \text{eğer } x < 0; \\ x & \text{eğer } x \geq 0 \end{cases} \quad (6)$$

Eşitlik 7'de yer alan swish fonksiyonunun en önemli avantajı negatif bölgelerde de değer alması ve her noktada türevinin alınabiliyor olmasıdır. Swish fonksiyonunun olumsuz yönü ise çıktının girdinin arttığı zamanlarda düşüşe geçebiliyor olmasıdır. Eşitlik 8'de görüldüğü üzere swish fonksiyonu eğitim parametresi (β) kullanılacak şekilde de tanımlanabilmektedir.

$$\text{Swish}(x) = x \cdot \text{Sigmoid}(x) \quad (7)$$

$$\text{Swish}(x, \beta) = 2x \cdot \text{Sigmoid}(\beta \cdot x) \quad (8)$$

Görüldüğü üzere her aktivasyon fonksiyonunun diğer fonksiyonlara göre artı ve eksi yönleri bulunmaktadır. Hangi aktivasyon fonksiyonunun kullanılması gerektiği konusunda da kesin bir kural bulunmamakla birlikte, derin öğrenme ve çok katmanlı sinir ağlarında türev değerlerinin uç noktalarda sifira yakınsaması problemi sebebiyle Hiperbolik Tanjant ve Sigmoid fonksiyonları; 0 değer bölgesinde türevin 0 olması ve öğrenmenin gerçekleşmemesi sebebiyle de ReLU fonksiyonunun kullanılması bu modellerde verimli sonuçların alınmasını engelleyebilmektedir.

Çalışmada, eğitim sürecinin daha hızlı olması ve veri değerlerindeki büyüklük farklarına dayalı hataların önlenmesi, ayrıca uç değerlerin de tahminde öneminin olması sebebiyle MinMax Ölçeklendirme Yöntemi kullanılmış, tüm veriler -1 ve +1 aralığında ölçeklendirilmiştir. Aktivasyon fonksiyonu olarak da yukarıda ifade edilen problemlerin önlenmesi amacıyla tüm nöronlarda Leaky ReLU fonksiyonu kullanılmıştır.

Kayıp fonksiyonları, yapay sinir ağı modellerinde tahminlerin başarısının ölçülmesi ve değerlendirilmesinde kullanılmaktadır. Kayıp fonksiyonlarından elde edilen değerler düşükse model başarılı, yüksekse başarısız sonuçlar verecektir. Uygulamada Ortalama Mutlak Hata (Mean Absolute Error), Ortalama Kareli Hata (Mean Squared Error), Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error), Kök Ortalama Kareli Hata (Root Mean Squared Error) en çok kullanılan kayıp fonksiyonları olup; çoklu sınıflandırma, ikili sınıflandırma gibi farklı modellemelerde farklı kayıp fonksiyonları da kullanılmaktadır. Tahmin değeri ile gerçek değer arasındaki sapmayı ölçen en basit hata terimi aşağıdaki şekilde hesaplanmaktadır.

$$e_i = y_i - \hat{y}_i \quad (9)$$

Formülde e_i kaybı (hatayı), y_i gerçek değeri, \hat{y}_i ise tahmin değerini ifade etmektedir. Hatalar pozitif ve negatif değer alabildiği için bu hataların toplamının 0'a yakınsama sorunu oluşacağından, mutlak değerleri alınarak Ortalama Mutlak Hata (MAE) hesaplanır.

$$MAE = \frac{1}{n} \sum |e_i| \quad (10)$$

Ortalama Mutlak Yüzde Hata (MAPE) ise hataların gerçek değerlere oranlarının mutlak değerleri üzerinden hesaplanmaktadır.

$$MAPE = \frac{1}{n} \sum \left| \frac{e_i}{y_i} \right| \quad (11)$$

Ortalama Kareli Hata (MSE) ve Kök Ortalama Kareli Hata (RMSE) hesaplamaları ise aşağıdaki gibidir.

$$MSE = \frac{1}{n} \sum (e_i)^2 \quad (12)$$

$$RMSE = \sqrt{\frac{1}{n} \sum (e_i)^2} \quad (13)$$

Çalışmada, kayıp fonksiyonu olarak yaygın şekilde kullanılan Ortalama Mutlak Hata tercih edilmiş, ayrıca Ortalama Kareli Hata metrik (metrics) parametresi olarak belirlenmiştir⁴. Ancak modellerin genel başarılarının ölçülmesinde Ortalama Mutlak Hata ve Ortalama Mutlak Yüzde Hata değerleri hesaplanmış ve bu hata değerleri dikkate alınmıştır.

Öğrenme (optimizasyon) algoritmaları, eğitim veri seti üzerinden modelin eğitilmesi ve bu şekilde en düşük hatalara ulaşılarak en iyi tahmin değerlerini elde edebilmek için kullanılan algoritmalarlardır. Bu algoritmalarda optimizasyonu gerçekleştirebilmek için Gradyan İnişi (Gradient Descent) Yöntemi kullanılarak ağırlıklar güncellenir. Gradyan İniş Yöntemlerini kullanan Momentum, AdaGrad, RMSprop, Adadelta, Adam gibi çeşitli öğrenme algoritmaları geliştirilmiştir. Bu algoritmalar formül 1'de verilen SGD'nin geliştirilmiş versiyonlarıdır.

⁴ Metrics parametresi, eğitim aşamasında her epoch sonrası bir sinama yaparak sonuçları ve model başarısını değerlendirmek için kullanılmaktadır.

SGD'de optimum nokta aranırken çok fazla salınım olmaktadır. Bu salınımları azaltmak ve dolayısıyla hedefe gitme hızını arttırmak için Momentum Yöntemi önerilmektedir (Seyyarer, Ayata, Uşkan ve Karcı, 2020, s. 93). Momentum Yönteminde, ağırlığı güncellemek yalnızca mevcut eğime bağlı olmak yerine; mevcut eğim, bir eğim toplamı olan momentum ile değiştirilir. Bu toplam, mevcut ve geçmiş gradyanların üstel hareketli ortalamasıdır (Karim, 2018). Momentum hesaplaması aşağıdaki formüllerde yer almaktadır.

$$w_{t+1} = w_t - \alpha m_t \quad (14)$$

$$m_t = \beta m_{t-1} + (1 - \beta) \frac{\partial L}{\partial w_t} \quad (15)$$

AdaGrad (Adaptive Gradient); SGD ve Momentum Yöntemlerindeki sabit öğrenme katsayısını değiştirebilmek amacıyla geliştirilmiş bir algoritmadır. AdaGrad, öğrenme oranını, mevcut ve geçmiş kare gradyanların kümülatif toplamı olan v değerinin kareköküne bölerek öğrenme oranı bileşeni üzerinde hareket eder (Karim, 2018). Eşitlik 16'da yer alan ϵ değeri, sıfıra bölme problemiyle karşılaşılması için Keras kütüphanesinin formüle eklediği çok küçük bir değerdir.

$$w_{t+1} = w_t - \frac{\alpha}{\sqrt{v_t + \epsilon}} \cdot \frac{\partial L}{\partial w_t} \quad (16)$$

$$v_t = v_{t-1} + \left(\frac{\partial L}{\partial w_t} \right)^2 \quad (17)$$

RMSprop, AdaGrad Yöntemini iyileştirmeye çalışan başka bir uyarlanabilir öğrenme oranıdır. Kare gradyanların kümülatif toplamını almak yerine, bu kare gradyanların üstel hareketli ortalamasını almaktadır (Karim, 2018). Hesaplama şekli aşağıdaki formüllerde yer almaktadır.

$$w_{t+1} = w_t - \frac{\alpha}{\sqrt{v_t + \epsilon}} \cdot \frac{\partial L}{\partial w_t} \quad (16)$$

$$v_t = \beta v_{t-1} + (1 - \beta) \left(\frac{\partial L}{\partial w_t} \right)^2 \quad (18)$$

Adadelta da, AdaGrad'in öğrenme oranı bileşenine odaklanan bir başka iyileştirme yöntemidir. Adadelta ve RMSprop arasındaki fark, Adadelta'nın öğrenme oranı parametresinin kullanımını D (kare deltaların üstel hareketli ortalaması) ile değiştirerek tamamen kaldırmasıdır (Karim, 2018). Bu algoritmadaki delta değerleri, geçerli ağırlıklar ile güncellenen ağırlıklar arasındaki farkı ifade etmektedir. Aşağıdaki formüllerde hesaplama biçimi görülmektedir.

$$w_{t+1} = w_t - \frac{\sqrt{D_{t-1} + \epsilon}}{\sqrt{v_t + \epsilon}} \cdot \frac{\partial L}{\partial w_t} \quad (19)$$

$$D_t = \beta D_{t-1} + (1 - \beta) (\Delta w_t)^2 \quad (20)$$

$$v_t = \beta v_{t-1} + (1 - \beta) \left(\frac{\partial L}{\partial w_t} \right)^2 \quad (18)$$

$$\Delta w_t = w_t - w_{t-1} \quad (21)$$

Adam (Adaptive Moment Estimation), Momentum ve RMSprop'un bir birleşimidir. Adam, Momentum ve RMSprop Yöntemlerindeki m ve v değerleri üzerinden aşağıdaki şekilde hesaplanmaktadır.

$$w_{t+1} = w_t - \frac{\alpha}{\sqrt{\hat{v}_t + \epsilon}} \cdot \hat{m}_t \quad (22)$$

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (23)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (24)$$

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \frac{\partial L}{\partial w_t} \quad (25)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) \left(\frac{\partial L}{\partial w_t} \right)^2 \quad (26)$$


Uygulamada Adam algoritması üzerinden geliştirilen AdaMax, Nadam, AMSGrad gibi farklı algoritmalar da mevcuttur. Çalışmada, öğrenme algoritması (optimizer) olarak Adam algoritması tercih edilmiştir.

Ölçeklendirme yöntemi, aktivasyon fonksiyonu, kayıp fonksiyonu ve öğrenme algoritmasının belirlenmesinden sonra eğitim (training) seti toplam verinin %70'i, doğrulama (validation) seti toplam verinin % 15'i ve test seti toplam verinin % 15'i olacak şekilde veriler üç gruba bölünmüştür⁵. En uygun mimarinin oluşturulabilmesi amacıyla deneme modellerine başlamadan önce batch size (grup boyutu) ve epoch (döngü) sayısının belirlenmesi gerekmektedir. Derin öğrenmede, her iterasyonda geriye yayılım ile ağırlıkların güncellenmesi amacıyla gradyan hesaplamaları yapılmakta, bu nedenle veri ne kadar çoksa bu hesaplama işlemleri de o kadar uzun sürmektedir. Batch size modelin aynı anda kaç veriyi işleyeceğini gösteren parametredir. Bu sayede eğitim verilerinin tamamı aynı anda değil parçalar hâlinde eğitime katılmaktadır. Her bir eğitim adımında gradyan hesaplamaları yapılarak model için en uygun ağırlık değerleri hesaplanmaya çalışılır. Bu eğitim adımlarının her birine ise epoch denilmektedir. Eğitim verilerinin batch size büyüklüğüne göre kaç gruptan oluşacağı belli olduktan sonra, bu grup sayısı ile epoch sayısının çarpımı ise iterasyon sayısını verecektir. Çalışmada batch size 10, epochs ise 1000 olarak belirlenmiş ve modellerin denemeleri yapılmıştır.

Derin öğrenme modellerinde dikkat edilmesi gereken önemli bir diğer konu overfitting (aşırı öğrenme) sorunudur. Eğer model, eğitim verileri üzerinde çok düşük hata değerlerine ulaşırken test verilerinde hata değerleri yüksek çıkıyorsa, bu durumda modelde overfitting durumundan bahsedilebilir. Model eğitim setindeki verileri ezberlemesi sebebiyle bu verilere aşırı uyum gösterirken, modele daha önce hiç gösterilmeyen test verileri sunulduğunda ise yüksek hata değerleri ile karşılaşılır. Bu nedenle uygulamada, veriler üç kısma bölünerek (eğitim, doğrulama, test) eğitim sırasında overfitting sorunun oluşup oluşmadığı izlenir. Model, eğitim verileri üzerinde öğrenme algoritmaları ile çalışırken ağırlıkları günceller. Doğrulama verileri ise bu işleme tabi tutulmaz. Her iterasyon sonrasında bu veriler modele verilip tespit edilen ağırlıklar kullanılarak doğrulama verilerinin hataları hesaplanır. Böylece eğitim ve doğrulama verilerinin hataları birlikte incelenerek modelin uygunluğu değerlendirilir. Modelde eğitim ve doğrulama verileri açısından uyum görülürken, test verileri sunulduğunda daha yüksek hata değerleri oluşuyorsa overfitting durumundan tekrar şüphe etmek gereklidir. Hiçbir model mükemmel olmamakla birlikte, uygun bir modelden beklenen bu üç veri seti için hataların uyumlu olarak gözlemlenmesidir. Bu nedenle, çalışmada en uygun mimariye sahip modelin tespit edilebilmesi amacıyla gerçekleştirilen denemelerde bu nokta göz önünde bulundurulmuştur.

Denemeler sonucu en uygun modelin tespit edilmesinden sonra aynı model Çapraz Doğrulama metodu kullanılarak tekrar incelenmiştir. Çapraz Doğrulama metodunda amaç elde edilen modelin başarı düzeyinin tesadüfi olup olmadığını değerlendirmektir. Bu yöntemde, kaç tur (k ile ifade edilir) gerçekleştirilmek isteniyorsa, belirlenen tur sayısına göre her verinin hem eğitim hem de doğrulama seti içerisinde kullanılacağı şekilde veri setleri tekrar oluşturulur. Bir önceki turda doğrulama setinde olan veriler, eğitim veri setine alınırken, önceki turda eğitim veri setinde olan veriler içerisinden yeni bir doğrulama seti oluşturulur. Ancak önceki turda doğrulama veri setine giren veriler, sonraki turlarda doğrulama veri setlerine tekrar alınmamaktadır. Veri setlerinin düzenlenmesinin ardından belirlenen parametreler doğrultusunda model çalıştırılarak tur sayısı kadar deneme yapılmaktadır.

⁵ Bölme işlemi gerçekleştirilirken ilk aşamada python sklearn kütüphanesi kullanılmakta, bölme işleminde öncelikle eğitim ve test verileri ayrıştırılmaktadır. Ancak bu bölme işlemi öncesinde sıralı halde olan veri seti karılmaktadır. Doğrulama veri seti ise tensorflow-keras kütüphanesi ile dizayn edilen derin öğrenme modelinin eğitim süreci başlatılmadan önce model parametre tanımlamaları esnasında eğitim veri seti içerisinden ayrıştırılmaktadır.



Kaynak: Ögündür (2020), <https://medium.com/@gulcanogundur>

Şekil 4. Çapraz Doğrulamada Veri Setlerinin Düzenlenmesi

Şekil 4'te, 5 tur için veri setlerinin nasıl oluşturulduğu gösterilmektedir. Her tur için veri setinin % 20'si doğrulama, % 80'i eğitim için ayrılmaktadır. Böylece tüm veriler gerçekleştirilecek beş farklı tur süreci sonunda hem eğitim, hem de doğrulama veri setlerinde kullanılmış olacaktır. Şekil 4'te sıralı bir bölme işlemi görülürken, bu bölme işlemi random (rastgele) şekilde de gerçekleştirilebilmektedir.

Çalışmada gerçekleştirilen Çapraz Doğrulama metodunda, ilk yöntemde elde edilen mimari ve model parametreleri ile algoritmalar aynı şekilde kullanılmış, tur sayısı 5 olarak belirlenmiş, veriler ise random şekilde ayrıştırılmıştır.⁶

Bulgular ve Tartışma


İlk yöntemde, eğitim, doğrulama ve test verileri hata değerlerinin tutarlılığı dikkate alınarak (overfitting durumunun oluşmaması), en düşük hata değerlerine ulaşabileceğimiz modelin tespit edilebilmesi amacıyla birçok deneme yapılmıştır. Denemeler sonucunda elde edilen en uygun modele ait mimari, Tablo 2'de sunulmuştur.

Tablo 2
En Uygun Derin Öğrenme Modelinin Mimari Yapısı

Katmanlar	Girdi, Nöron ve Çıktı Sayıları
Giriş Katmanı	14 Girdi (Değişken)
1. Katman	14 Nöron
2. Katman	7 Nöron
3. Katman	4 Nöron
4. Katman	2 Nöron
Çıktı Katmanı	1 Çıktı (Tahmin)

⁶ Çapraz Doğrulama Yöntemi, python üzerinden Sklearn-KFlod kütüphanesi kullanılarak gerçekleştirilmiştir.

Modelin eğitim süreci tamamlandıktan sonra, kayıp fonksiyonlarının grafiği incelenmiş, modelde overfitting sorununa ilişkin bir problem gözlenmemiştir.



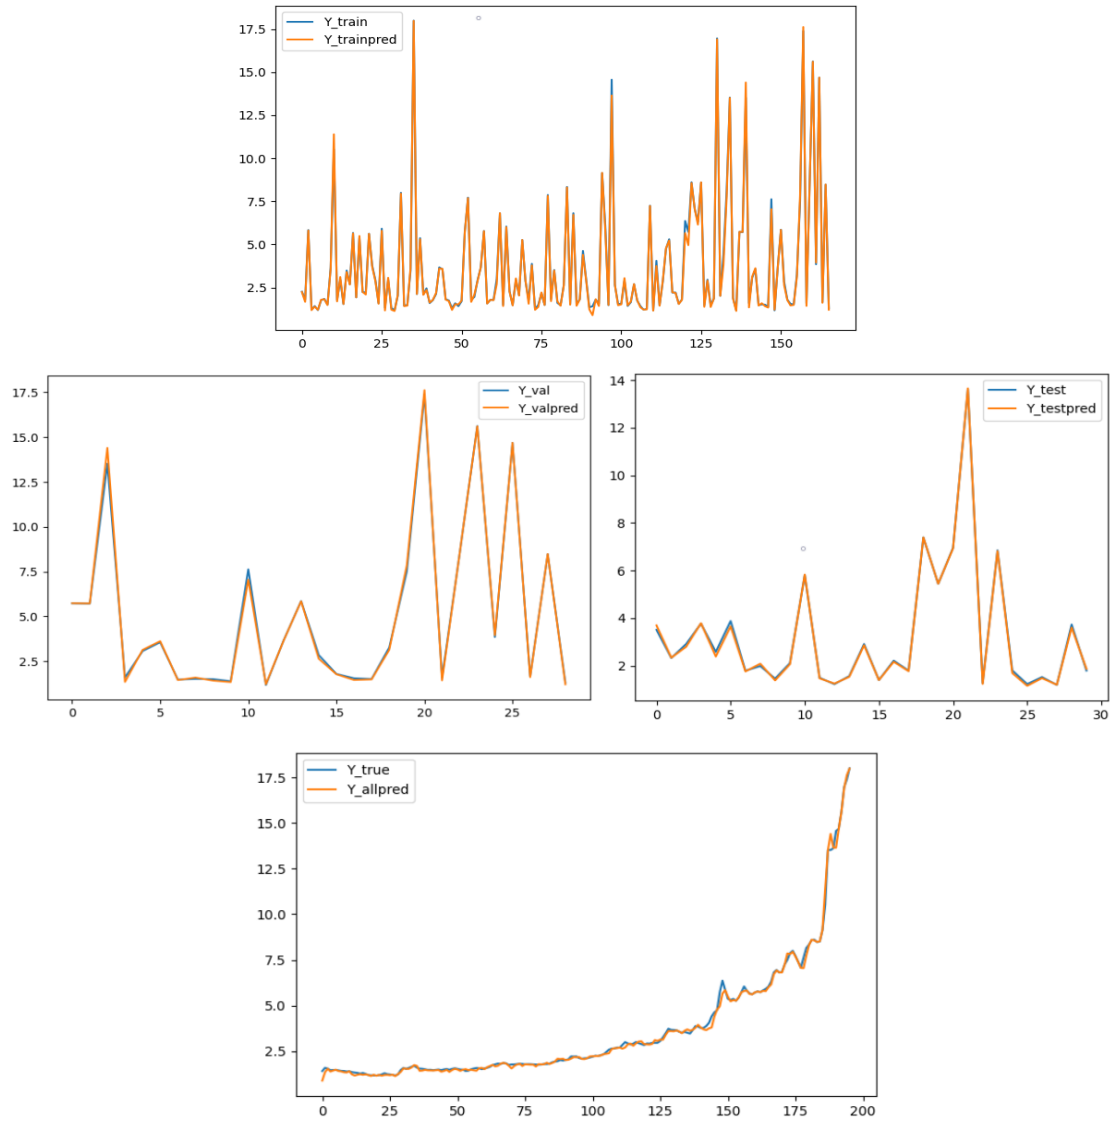
Şekil 5. Model Kayıp Grafikleri (*loss: mae, *metrics: mse)

Bu aşamadan sonra, modelden elde edilen tahmin (predict) değerleri ölçeklendirilmiş formdan normal değerlere çevrilmiş, eğitim, doğrulama ve test setlerinin hata değerleri hesaplanarak modelin başarıları değerlendirilmiştir.

Tablo 3
Model Hata Değerleri

Veri Seti	MAE	MAPE
Eğitim	0.0968	0.0318
Doğrulama	0.1259	0.0354
Test	0.0599	0.0254
Hepsi	0.0912	0.0308

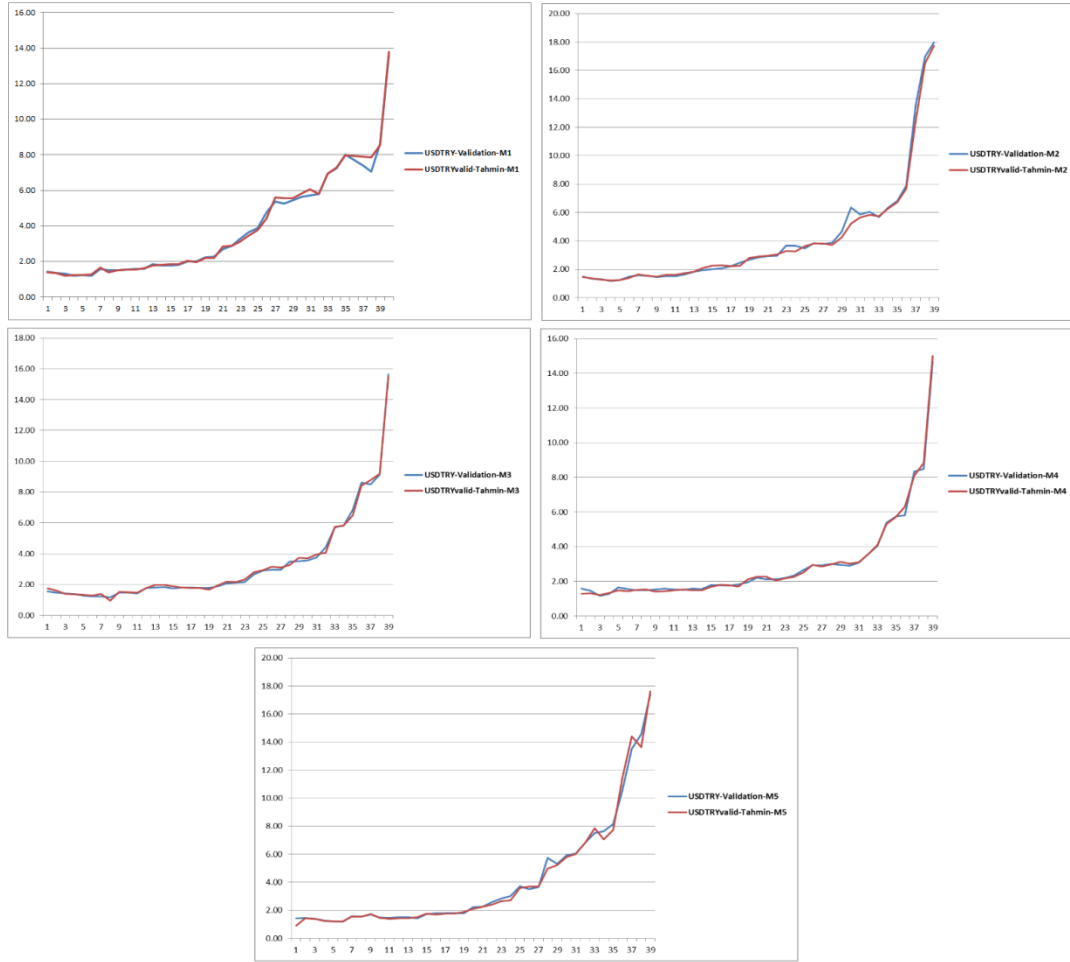
Modele test verilerini sunduğumuzda, MAE ve MAPE değerleri açısından modelin başarılı sonuçlar ürettiği görülmektedir. Eğitim, doğrulama, test setleri ve tüm veri seti açısından MAPE değerlerini incelendiğinde modelin tutarlılık açısından da uygun olduğu söylenebilmektedir. Model sonuçlarına göre, % 2,54 ile % 3,54 arası hatayla doğru tahminler üretilmektedir. Şekil 6'da modelin eğitim, doğrulama ve test setleri ile tüm veri setine ait tahmin değerleri ile gerçek değerleri gösteren grafikler yer almaktadır.



Şekil 6. Model Tahmin Değerleri ve Gerçek Değerler (*üst: eğitim, *sağ: test, *sol: doğrulama, *alt: tüm set)

İkinci yöntemde, çapraz doğrulama ile modelin tutarlılığı incelenmiştir. Beş tur sonucunda, doğrulama setlerine yönelik model tahmin değerleri ve gerçek değerler Şekil 7’de sunulmuştur.⁷

⁷ Çapraz Doğrulama Yönteminde eğitim, doğrulama ve tüm veri setleri için gerçek değerler ile beş modelin ürettiği ayrı ayrı tahmin değerleri Excel formatında kaydedilmiş ve grafikler Excel üzerinden oluşturulmuştur.



Şekil 7. Çapraz Doğrulama Yöntemi - Doğrulama Setleri Tahmin Değerleri ve Gerçek Değerler

Tablo 4
Çapraz Doğrulama Hata Değerleri

Tur	Eğitim		Doğrulama		Hepsi	
	MAE	MAPE	MAE	MAPE	MAE	MAPE
Model 1	0.0910	0.0305	0.1248	0.0332	0.0979	0.0311
Model 2	0.0754	0.0278	0.1807	0.0445	0.0963	0.0311
Model 3	0.0855	0.0309	0.1150	0.0460	0.0914	0.0339
Model 4	0.0892	0.0339	0.1103	0.0440	0.0934	0.0359
Model 5	0.0647	0.0267	0.1982	0.0475	0.0912	0.0308
Ort.	0.0812	0.0300	0.1458	0.0430	0.0941	0.0326

Çapraz Doğrulama Yöntemi ile gerçekleştirilen 5 tur sonucunda modellerin MAE ve MAPE değerlerini incelediğimizde, ikinci ve beşinci modelde eğitim ve doğrulama setlerinin hata değerlerinin bir miktar farklılaştığı, ancak diğer üç modelde tutarlı olduğu görülmektedir. Beş modelin hata ortalamalarını incelediğimizde, eğitim setleri MAPE ortalaması % 3, doğrulama setleri MAPE ortalaması % 4,3 ve tüm veri

setlerinde MAPE ortalaması % 3,26'dır. Aynı mimari ve parametrelerle gerçekleştirilen çapraz doğrulama sonuçlarına göre modellerde hata hesaplamaları açısından çok farklı değerlerle karşılaşmamıştır. İlk yöntemde tüm veri seti açısından MAE değeri 0,0912 ve MAPE değeri % 3,08 iken; çapraz doğrulama sonucunda tüm veri setleri ortalaması açısından MAE değeri 0,0941 ve MAPE değeri % 3,26'dır. Sonuçlar ilk yöntemde elde edilen mimarinin tutarlılığını destekler yöndedir.

Derin öğrenme mimarisi ve kullanılan parametreler açısından, çapraz doğrulama sonrasında modelin tutarlılığına yönelik olumlu sonuçlara ulaşılmış, son aşamada değişkenlere ait Eylül 2022 ve Ekim 2022 verileri önceki veri setine eklenerek, USD/TRY döviz kurunun bu iki ay için ay sonu değerleri tahmin edilmiştir.⁸ Oluşturulan derin öğrenme modeli ölçeklendirilmiş veriler üzerinden çalıştığı için, yeni veri seti MinMax Scaler (-1,+1) kullanılarak tekrar ölçeklendirilmiş, ilk yöntemde fit edilerek kaydedilen model üzerinden tahminler gerçekleştirilmiştir. Tahmin sonuçları tekrar ölçeklendirilmiş formdan normal değerlere çevrilmiş, Tablo 5'te sunulmuştur.

Tablo 5

USD/TRY Döviz Kuru Eylül 2022 ve Ekim 2022 Tahmin ve Hata Değerleri

Dönem	Gerçekleşen USD/TRY Kuru	Tahmin Edilen		Mutlak Hata (AE)	Mutlak Yüzde Hata (APE)
		USD/TRY Kuru	Hata		
Eyl.22	18.2814	17.7281	-0.5533	0.5533	0.0303
Eki.22	18.5646	17.9335	-0.6311	0.6311	0.0340

Model tahmin sonuçlarında, Eylül 2022 için mutlak yüzde hata (APE) % 3,03 iken Ekim 2022 için mutlak yüzde hata % 3,40'tır. Gerçekleşen hata değerleri modelin hata sınırları içerisinde olup, modelin bu hata sınırları içerisinde yaklaşık tahminler üretebildiği görülmektedir.

Sonuç

Çalışmada, USD/TRY döviz kurunun ay sonu değerlerini tahmin etmek amacıyla derin öğrenme metodu kullanılmıştır. Çalışmanın ilk aşamasında, veriler eğitim, doğrulama ve test verileri olarak ayrıştırılarak farklı derin öğrenme mimarileri denenmiş ve overfitting probleminin oluşmaması için hata oranlarındaki tutarlılığa dikkat edilerek en düşük hata oranlarının elde edildiği derin öğrenme modeli tespit edilmiştir. Modelin daha önce görmediği test verileri modele sunulduğunda tahmin sonuçlarının hata değerleri açısından tutarlı olduğu görülmüştür. Sonraki aşamada Çapraz Doğrulama Yöntemi uygulanmış, beş tur gerçekleştirilmiş ve modellerdeki hata hesaplamaları açısından çok farklı değerlerle karşılaşmamıştır. İlk yöntemde modelin tüm veriler üzerinden gerçekleştirdiği tahminler için MAE değeri 0,0912 ve MAPE değeri % 3,08 iken; Çapraz Doğrulama Yönteminde tüm veriler üzerinden gerçekleştirilen tahminler sonucunda beş turdaki modellerin ortalaması açısından MAE değeri 0,0941 ve MAPE değeri % 3,26 olarak gerçekleşmiştir. İki farklı yöntemden elde edilen bulgular sonucunda derin öğrenme için ilk yöntemde tespit edilen modelin tutarlı olduğu kanaatine varılmıştır. Modelin gelecek aylardaki USD/TRY değerlerinin tahmin başarısını görebilmek amacıyla, Eylül

⁸ Cari işlemler hesabı ve net hata noksan hesabı aylık veriler üzerinden yıllıklandırılmaktadır. TCMB, kasım ayı ikinci haftasında ödemeler dengesi verileri ile ilgili geçmiş verileri de kapsayacak şekilde bir düzeltmeye gitmiştir. Çalışmanın uygulama aşamasında, cari işlemler ve net hata noksan hesaplarına ilişkin değişkenlerde düzeltme öncesi veriler kullanıldığı için, bu değişkenlere ait Eylül ve Ekim 2022 (Temmuz ve Ağustos 2022 gerçekleşmeleri) yıllıklandırması yapılırken bu iki aya ait aylık değerler düzeltme öncesi aylık veri setinin devamına eklenerek yıllıklandırma işlemi bu şekilde gerçekleştirilmiştir.

2022 ve Ekim 2022 ayları için gerçekleştirilen tahminlerde hata değerlerinin modelin hata sınırları içerisinde olduğu görülmüş ve model başarısı tekrar teyit edilmiştir. Derin öğrenme modelinin belli hata sınırları içerisinde gerçek değerlere oldukça yakın tahmin değerleri üretebildiği görülmüştür.

Alım – satım (trade) işlemleri açısından % 3 - % 3,5 düzeyindeki hata oranlarının yüksek olduğunu söyleyebiliriz. Ancak derin öğrenme modelleri ile belirli hata aralıklarında gerçekleştirilen tahminler, alım – satım işlemleri açısından döviz kurunun ay sonu dip ve tepe seviyeleri konusunda alternatif bir bilgi sağlayabileceği gibi, geleceğe yönelik kararlarda döviz kuru seviyelerini öngörebilmek açısından ekonomideki karar vericilere de fayda sağlayacaktır. Çalışma bulgularına göre, makroekonomik değişkenler (değişkenlerin açıklanma takvimine bağlı olarak bir veya iki ay önceki gerçekleşmeleri ve bu açıklanan verilerin bir gecikmeli değerleri) üzerinden USD/TRY döviz kurunun ay sonu değerlerini tahmin etmede derin öğrenme modelinin kabul edilebilir bir hata payı çerçevesinde başarılı olduğu görülmektedir. Modelde kullanılan bağımsız değişkenlerin USD/TRY döviz kurunun ay sonu seviyesini tahmin etme gücünün olduğu da görülmüştür.

Derin öğrenme metodunda, açıklanan yeni veriler data setine eklenip model tekrar eğitilebilmekte ve bu şekilde güncellenebilmektedir. Ayrıca zaman içerisinde akademik literatür ve güncel uygulamalar doğrultusunda önemli olacağı düşünülen yeni değişkenler modele eklenebileceği gibi, öneminin oldukça azaldığı ya da kalmadığı düşünülen değişkenler modelden çıkarılabilmekte ve mevcut modeller bu şekilde geliştirilebilmektedir. Derin öğrenme metodu bu açıdan sürekliliğe sahiptir. Çalışmada elde edilen modelin de ileride daha düşük hata değerleri ile daha iyi tahminler yapabilmesine yönelik geliştirilebilmesi mümkündür.

Kaynakça

- Alizadeh, M., Rada, R., Balagh, A. K. G. ve Esfahani, M.M.S. (2020). Forecasting exchange rates: A neuro-fuzzy approach. *UMBC Faculty Collection*. Erişim adresi: <http://hdl.handle.net/11603/20057>
- Anderson, J.A. (1972). A simple neural network generating on interactive memory. *Mathematical Biosciences*, 14, 197-220. [https://doi.org/10.1016/0025-5564\(72\)90075-2](https://doi.org/10.1016/0025-5564(72)90075-2)
- Bal, C. ve Demir, S. (2017). A comparative study of artificial neural network models for forecasting USD/EUR-GBP-JPY-NOK exchange rates. *Journal of Emerging Issues in Economics, Finance and Banking (JEIEFB)*, 6(2), 2248-2259. Erişim adresi: <https://www.researchgate.net/profile/Cagatay-Bal>
- Çınar, U.K. (2018, 13 Ağustos). Yapay sinir ağları ve R programıyla uygulama [Blog yazısı]. Erişim adresi: <https://www.veribilimiokulu.com/yapay-sinir-aglari/>
- Çuhadar, M., Demirbaş, K. ve Dayan, K. (2019). TÜFE bazlı reel efektif döviz kurunun alternatif yaklaşımlarla modellenmesi ve tahminlenmesi. *Süleyman Demirel Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 34, 78-103. Erişim adresi: <https://dergipark.org.tr/en/pub/sbe/issue/45116/564090>
- Doğan, F. ve Türkoğlu, İ. (2019). Derin öğrenme modelleri ve uygulama alanlarına ilişkin bir derleme. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi*, 10(2), 409-445. Erişim adresi: <https://dergipark.org.tr/en/pub/dumf/issue/45282/411130>
- Investing.com. Erişim adresi: <https://tr.investing.com/rates-bonds/>
- Karim, R. (2018, 22 Kasım). 10 stochastic gradient descent optimisation algorithms + cheatsheet [Blog yazısı]. Erişim adresi: <https://towardsdatascience.com/10-gradient-descent-optimisation-algorithms-86989510b5e9>
- Kızrak, A. (2019, 4 Şubat). Derin öğrenme için aktivasyon fonksiyonlarının karşılaştırılması [Blog yazısı]. Erişim adresi: <https://ayyucekizrak.medium.com/derin-%C3%B6%C4%9Frenme-i%C3%A7in-aktivasyon-fonksiyonlar%C4%B1n%C4%B1n-kar%C5%9F%C4%B1la%C5%9Ft%C4%B1r%C4%B1lmas%C4%B1-cee17fd1d9cd>
- Kim, Y.C., Lee, H.J., Kim, J.W. ve Ahn, J.J. (2018). A study on machine learning-based KRW/USD exchange rate prediction model using swap point determinants: Focused on optimal structure finding in multi layer perceptron. *The Korean Data & Information Science Society*, 29(1), 203-216. Erişim adresi: <http://www.kdiss.org/journal/view.html?uid=2320&&vmd=Full>
- Kohonen, T. (1972). Correlation matrix memories. *IEEE Transactions on Computers*, 21(4), 353-359. Erişim adresi: <https://lucidar.me/en/neural-networks/files/1972-correlation-matrix-memories.pdf>

- Li, L., Pan, F. ve Wang, C. (2020). Prediction analysis of USD-CNY trend based on BP neural network. *In 2020 International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering (ICBAIE)* (pp. 48-52), IEEE. Erişim adresi: <https://ieeexplore.ieee.org/abstract/document/9196462>
- McCulloch, W.S. ve Pitts, W.A. (1943). A logical calculus of the ideas immanent in nervous activity. *Buttetin of Mathematics and Biophysics*, 5, 115-133. Erişim adresi: <https://waldirbertazzijr.com/wp-content/uploads/2018/10/mcp.pdf>
- Minsky, M. ve Papert, S. (1969). *Perceptrons*. Cambridge, MA: MIT Press.
- Mohammadi, W.A.Z.I.R. (2019). *Currency exchange rate forecasting using machine learning techniques* (Yüksek lisans tezi). Graduate School of Applied Sciences, Near East University. Erişim adresi: <http://docs.neu.edu.tr/library/6721800683.pdf>
- Öğündür, G. (2020, 13 Ocak). Model seçimi - K fold cross validation [Blog yazısı]. Erişim adresi: <https://medium.com/@gulcanogundur/model-se%C3%A7imi-k-fold-cross-validation-4635b61f143c>
- Özkan, F. (2011). Döviz kuru tahmininde yapay sinir ağlarıyla alternatif yaklaşım. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 6(2), 185-200. Erişim adresi: <https://dergipark.org.tr/en/pub/oguiibf/issue/5718/76536>
- Özkan, F. (2012). Döviz kuru tahmininde parasal model ve yapay sinir ağları karşılaştırması. *Business and Economics Research Journal*, 3(1), 27-39. Erişim adresi: <https://www.berjournal.com/berjournal-ciltvolume-3-sayinumber-1-yilyear-2012.html>
- Öztemel, E. (2012). *Yapay sinir ağları* (Vol. 3). İstanbul: Papatya Yayıncılık Eğitim.
- Panda, C. ve Narasimhan, V. (2007). Forecasting exchange rate better with artificial neural network. *Journal of Policy Modeling*, 29(2), 227-236. <https://doi.org/10.1016/j.jpolmod.2006.01.005>
- Pradhan, R.P. ve Kumar, R. (2010). Forecasting exchange rate in India: An application of artificial neural network model. *Journal of Mathematics Research*, 2(4), 111-117. Erişim adresi: <https://pdfs.semanticscholar.org/1fa7/2f9c2bb812692d28fbf09f7783c89bc7ac7a.pdf>
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychoanalytic Review*, 65, 386-408. <https://doi.org/10.1037/h0042519>

- Rumelhart, D.E., McClelland, J.L. ve the PDP Research Group (1986). *Parallel distributed processing: Explorations in the microstructure of cognition. Volume 1: Foundations*. Cambridge, MA: MIT Press. Researchgate web sitesinden erişilen adres: https://www.researchgate.net/publication/200033859_Parallel_distributed_processing_explorations_in_the_microstructure_of_cognition_Volume_1_Foundations
- Seyyarer, E., Ayata, F., Uçkan, T. ve Karci, A. (2020). Derin öğrenmede kullanılan optimizasyon algoritmalarının uygulanması ve kıyaslanması. *Computer Science*, 5(2), 90-98. Erişim adresi: <https://dergipark.org.tr/en/pub/bbd/issue/57870/752132>
- Türkiye Cumhuriyet Merkez Bankası. Elektronik veri dağıtım sistemi. Erişim adresi: <https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket>
- Urrutia, J.D., Bariga, G.O. ve Putong, J.C.M. (2021). An analytical study on forecasting exchange rate in the Philippines using multi-layer feed forward neural network. *Turkish Journal of Computer and Mathematics Education*, 12(3), 5357-5377. <https://doi.org/10.17762/turcomat.v12i3.2182>
- Widrow, B. ve Hoff, M.E. (1960). *Adaptive switching circuits*. Stanford Univ Ca Stanford Electronics Labs. Erişim adresi: <https://apps.dtic.mil/sti/pdfs/AD0241531.pdf>
- Yavuz, S. ve Deveci, M. (2012). İstatiksel normalizasyon tekniklerinin yapay sinir ağı performansına etkisi. *Erciyes Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 40, 167-187. Erişim adresi: <https://dergipark.org.tr/en/pub/erciyesiibd/issue/5897/78019>

Extended Abstract

Purpose

Being able to predict the exchange rate with the lowest error rates will enable decision makers to make more accurate decisions for the future. In the study, it is aimed to predict the end-of-month values of the USD/TRY exchange rate through the macroeconomic data published in the current month in line with the data disclosure calendar, using artificial neural networks and deep learning method.

Design and Methodology

In the study covering the period 05:2006 - 08:2022, while the monthly data of the USD/TRY exchange rate is used as the dependent variable; the monthly data of Current Account (annualized), CPI Spread, Gross Foreign Exchange Reserves, Short-Term External Debt Stock, Two-Year Bond Interest Rate Spread, Net Error and Omission Account (annualized) and Money Supply (M1) are determined as independent variables. The CPI Spread and Two-Year Bond Rate Spread variables represent the difference between the USA and Turkey data. The independent variables show the occurrences of the previous month or two months ago in accordance with the data disclosure calendar. In addition, in order to take into account the past period effects, one-month delayed data of all independent variables were included in the model and a total of 14 independent variables were determined in the prediction of the USD/TRY exchange rate.

In the deep learning model, MinMax scaling method was used in order to make the training process faster and to prevent errors based on size differences in data values, and all data were scaled between -1 and +1. Leaky ReLU function was used in all neurons in order to ensure the learning process in negative values as an activation function. Mean Absolute Error (MAE), which is widely used as the loss function, was preferred, and Mean Squared Error (Mean Squared Error) was determined as the metrics parameter. However, Mean Absolute Error (MAE) and Mean Absolute Percentage Error (MAPE) values were calculated in measuring the overall success of the models and these error values were taken into account. The Adam algorithm was preferred as the learning algorithm (optimizer). Batch size was determined as 10 and epochs as 1000, and model trials were started using the python program. Firstly, the data were separated as training, validation and test sets, different deep learning architectures were tried with different layers and neuron numbers and the most suitable model was determined. In the second stage, the consistency of the determined model was examined by using the cross-validation method. At the last stage, USD/TRY exchange rates for September 2022 and October 2022 were estimated with the deep learning model.

Findings

The lowest error values were obtained in the architecture consisting of an input layer, four hidden layers (numbers of neurons: 14-7-4-2) and an output layer in the experiments carried out considering the consistency of error values (no overfitting). The prediction values obtained from the model were converted to normal values from the scaled form, and mean absolute percentage error (MAPE) values were calculated as 3.18% in the training set, 3.54% in the validation set, 2.54% in the test set, and 3.08% in the whole data set. It was seen that the model produced successful results when we presented the test data that it had not seen before.

In the next stage, as a result of 5 rounds carried out with the cross validation method, the MAPE average of the training sets of the models was calculated as 3%, the MAPE average of the validation sets was calculated as 4.3% and the MAPE average of all data sets was calculated as 3.26%. In the first method, while the MAE value is 0.0912 and the MAPE value is 3.08% for the entire data set; as a result of cross validation, the MAE value is 0.0941 and the MAPE value is 3.26% in terms of the average of all data sets. In terms of deep learning

architecture and the parameters used, positive results for the consistency of the model were obtained after cross validation.

At the last stage, the September 2022 and October 2022 data of the variables were added to the previous data set, and the month-end values of the USD/TRY exchange rate were estimated for these two months. In the forecast results, the absolute percentage error (APE) for September 2022 is 3.03%, while the absolute percentage error for October 2022 is 3.40%. The realized error values are within the error limits of the model, and it has been observed that the model can produce approximate estimates within these error limits. It has also been observed that the independent variables used in the model have the power to predict the month-end level of the USD/TRY exchange rate.

Research Limitations

In the deep learning method, there are many opportunities to experiment by using different activation functions, different parameters and different learning algorithms, but this process takes a long time due to the computer calculations taking a lot of time. For this reason, a certain standard had to be followed in the selection of parameters and functions in the study.

Implications

Forecasts made with deep learning models at certain error intervals can provide an alternative information about the month-end low and high levels of the exchange rate in terms of buying and selling transactions, and predicting the exchange rate levels will be beneficial for the decision makers in the economy for the future decision-making processes. It is possible to retrain the model obtained in the study, and it is also possible to develop the model in order to make better predictions with lower error values in the future.

Originality/Value

The study provides a new contribution to the analysis of model consistency by using the cross validation method, among the studies on estimating exchange rates in Türkiye with the deep learning method.

Araştırmacı Katkısı: Ersin GÜMÜŞ (%100).

Teşekkür: Levent Soner'e desteklerinden dolayı teşekkürlerimi iletiyorum.