



**AMERİKAN DOLARI KURUNUN YAPAY SİNİR AĞLARI YÖNTEMİYLE  
TAHMİNLENMESİ: 2009 – 2021 DÖNEMİ \***

*Estimating The American Dollar Exchange Rate By Artificial Neural Networks: 2009 – 2021  
Period*

**Tahsin Galip Tekin**

Arş. Gör., Batman Üniversitesi İşletme Bölümü, Bingöl Üniversitesi İşletme ABD Doktora  
Öğrencisi, [tahsingalip.tekin@batman.edu.tr](mailto:tahsingalip.tekin@batman.edu.tr) Bingöl / Türkiye  
<https://orcid.org/0000-0002-2642-5838>

**Sait PATIR**

Prof. Dr., Bingöl Üniversitesi İşletme Bölümü, [spatir@bingol.edu.tr](mailto:spatir@bingol.edu.tr) Bingöl / Türkiye  
<https://orcid.org/0000-0002-1592-1094>

**Doi:** <https://doi.org/10.33723/rs.1232231>

Tekin, T. G. & Patır, S. (2023). “Amerikan doları kurunun yapay sinir ağları yöntemiyle tahminlenmesi: 2009 – 2021 dönemi”, *R&S- Research Studies Anatolia Journal*, 5(3). 56-77

**Makale Türü:** Araştırma Makalesi

**Geliş Tarihi/ Arrived Date:** 11.01.2023

**Kabul Tarihi / Accepted Date:** 31.01.2023

**Yayınlanma Tarihi / Published Date:** 31.01.2023

\* Bu çalışma, Tahsin Galip TEKİN tarafından Bingöl Üniversitesi Sosyal Bilimler Enstitüsü bünyesinde, Prof. Dr. Sait PATIR danışmanlığında hazırlanmakta olan “Kripto Para Piyasası Günlük Değer Tahminlemede Nicel Yöntemlerin Kullanılması” adlı doktora tezinden türetilmiştir.

## ÖZ

Bu çalışmada Türk Lirası cinsinden Amerikan Doları (çalışmanın geri kalan kısmında dolar olarak anılacaktır) kuru değerinin yapay sinir ağları yöntemiyle tahminlenmesi ve yapay sinir ağları yönteminin dolar kuru tahminlemesinde başarılı olup olmadığının tespitinin yapılması hedeflenmektedir. Bu amaçla yapay sinir ağı, 2009 - 2021 dönemindeki yedi ayrı zaman serisine ait verilerle eğitilerek aynı dönem tahminlenmiştir. Tahmin değerleri gerçek değerlerle karşılaştırılmış ve hata metrikleri hesaplanmıştır. Çalışmada kullanılan tüm veriler Türkiye Cumhuriyet Merkez Bankası Elektronik Veri Dağıtım Sistemi'nden alınmıştır. Veriler MATLAB 2013 programı aracılığıyla analiz edilmiştir. Yapılan analiz sonrası MAE, MSE ve MAPE hata metrikleri hesaplanmıştır. Elde edilen sonuçlara göre MSE değeri 0,0019355, MAE değeri 0,01738, MAPE değeri ise 0,5137 olarak hesaplanmıştır. Bu bulgu kurulan modelin % 0,5137 (yaklaşık binde beş) hata oranı ile dolar kurunu tahmin ettiğini göstermektedir.

**Anahtar Kelimeler:** Dolar, Yapay Sinir Ağları, Tahminleme.

## ABSTRACT

In this study, it is aimed to estimate the exchange rate of US Dollar in Turkish Lira (referred to as dollar in the rest of the study) by artificial neural network method and to determine whether the artificial neural network method is successful in estimating the dollar exchange rate. For this purpose, the artificial neural network was trained with the data of seven different time series in the period 2009 - 2021 and the same period was estimated. Estimated values were compared with actual values and error metrics were calculated. All data used in the study were obtained from the Central Bank of the Republic of Turkey Electronic Data Delivery System. The data were analyzed using the MATLAB 2013 program. After the analysis, MAE, MSE and MAPE error metrics were calculated. According to the results obtained, the MAE value was calculated as 0,01738, the MSE value as 0,0019355, and the MAPE value as 0,5137. This finding shows

that the established model estimates the dollar exchange rate with an error rate of 0,5137% (approximately five per thousand).

**Keywords:** Dollar, Artificial Neural Networks, Estimating.

## GİRİŞ

Rezerv para uluslararası piyasalarda kabul görmüş ortak para birimine verilen addır. Günümüzde her ne kadar EURO ve dolar arasında rezerv para olma konusunda bir mücadele olsa da, 1944 yılında yapılan Bretton Woods anlaşmasıyla dolar rezerv para olarak kabul edilmiştir (Kargül, 2011: 139). Dolar bu özelliğiyle uluslararası piyasada en çok rağbet gösterilen ve dış ticarete en yoğun olarak kullanılan para birimidir. Bu özellikleriyle dolar kurunun ilerleyen dönem değerlerinin tahminlenmesi önem kazanmakta ve yatırımcıların ilgisini çekmektedir. Finansal zaman serileri çeşitli nicel tahmin yöntemleriyle tahminlenebilmektedir. Yapay sinir ağları yöntemi de bu yöntemlerden biridir.

Yapay sinir ağları literatürde ilk kez McCulloch ve Pitts (1943) tarafından yapılan çalışmayla tanımlanmıştır. Bu çalışmada bir nöron (sinir hücresi), diğer nöronlardan veri alan ve bu veriye bağlı olarak etkinleştirilen veya devre dışı bırakılan bir yapı olarak modellenmiştir (Krogh, 2008: 195). Bu gelişmenin ardından Hebb (1949) yaptığı çalışmayla günümüzde hala kullanılmakta olan öğrenme kuralını geliştirdi. Hebbian öğrenme kuralı adı verilen kuralı tanımlayan bu çalışmayı takip eden 10 yıl içerisinde çok sayıda yeni model geliştirildi (Ekin ve Akdoğan, 2018: 247). Rosenblatt (1958) yaptığı çalışmada sadece girdi ve çıktı katmanlarından oluşup “Perceptron” adı verilen ve çok katmanlı algılayıcıların temelini oluşturan tek katmanlı algılayıcıyı geliştirdi (Saatçioğlu ve Özçakar, 2016: 16). Bu temel çalışmaların ardından günümüze kadar yapay sinir ağları teknolojisinde çok sayıda gelişme yaşandı. Yapay sinir ağları birçok farklı disiplinden araştırmacı tarafından örüntü tanıma, tahmin, optimizasyon gibi çeşitli fonksiyonlarıyla kullanılmaktadırlar (Jain ve Mao, 1996:31). Çalışmada altı makro ekonomik değişken girdi olarak kullanılarak yapay sinir ağları eğitilmiş ve dolar kuru

tahminlenmiştir. Çalışmada kullanılan girdi değişkenleri (bağımsız değişkenler) aylık ortalama TÜFE zaman serisi, aylık ortalama bankalar ihtiyaç kredisi faiz oranları zaman serisi, bir ons altının dolar cinsinden aylık ortalama değeri zaman serisi, aylık ortalama BIST100 endeksi zaman serisi, külçe altın aylık ortalama gram fiyatı zaman serisi ve Türkiye Cumhuriyet Merkez Bankası aylık M3 para arzı zaman serisidir. Çalışmada MAE, MSE ve MAPE hata metrikleri hesaplanarak kurulan yapay sinir ağının tahmin performansı değerlendirmeye tabi tutulmuştur. Yapılan bu çalışma ile ilgili girdi değişkenlerinin dolar kurunu tahminlemede kullanımının etkin olup olmadığı tespit edilmesi ve çalışmanın bu yönüyle literatüre katkı sunması hedeflenmektedir. Çalışma sonucunda elde edilen bulgular yapılan tahminlemenin başarılı olduğunu göstermektedir. Çalışmanın devam eden bölümlerinde literatür taraması, yöntem, uygulama, sonuç ve öneriler ile kaynakça bölümlerine yer verilmiştir.

### LİTERATÜR TARAMASI

Bu bölümde literatürde bulunan ve yapay sinir ağları yöntemiyle finansal zaman serileri analizi yapan çalışmaların bir kısmının özet bilgileri verilmiştir. İlgili çalışmalar incelendiğinde, yapay sinir ağları yönteminin finans literatüründe zaman serisi değerlerinin öngörülenmesi, finansal başarısızlık tahmini gibi çeşitli araştırmalarda kullanıldığı görülmektedir.

Tkacz (2001) yaptığı çalışmada Kanada'nın gayri safi yurtiçi hâsılası büyüme oranlarını yapay sinir ağları yöntemi yanı sıra üstel düzeltme ve otoresif model gibi doğrusal, tek değişkenli modellerle tahminlemiştir. Çalışma sonucunda elde edilen bulgularda yapay sinir ağları ile kurulan modellerin, diğer modellere göre daha düşük tahmin hatası verdikleri görülmüştür. Fakat modellerin verdikleri hatalar arasındaki fark üç aylık gayri safi yurtiçi hâsıla tahminlemesi için kurulan modellerde daha düşük seviyede bulunmuştur.

Tektaş ve Karataş (2004) yaptıkları çalışmada İstanbul Menkul Kıymetler Borsası'nda işlem gören gıda ve çimento sektöründeki yedi şirketin hisse senedi değerlerini yapay sinir ağları

kullanarak tahminlemeye çalışmışlardır. Çalışmada ilk etapta yapay sinir ağları ile günlük ve haftalık veriler tahminlenmiş, günlük verilerle daha başarılı sonuçlar alınmıştır. Ardından günlük veriler yapay sinir ağları ve regresyon yöntemiyle analiz edilmiş, yapay sinir ağları yönteminin regresyon yönteminden daha iyi bir tahmin performansı sergilediği tespit edilmiştir.

Roh (2007) yaptığı çalışmada hisse senedi fiyatının oynaklığını tahminlemek için yapay sinir ağı ve diğer zaman serisi tekniklerini melezleyen bir model önermektedir. Çalışma sonucunda elde edilen bulgulara göre melez modelin sapma perspektifi ve yön doğruluğu için tahmin gücü yüksektir. Deneysel sonuçlar, önerilen melez NN – EGARCH modelin hisse senedi fiyatı oynaklığının tahmininde geliştirilebileceğini göstermiştir.

Akkaya vd. (2009) yaptıkları çalışmada finansal başarısızlık tahminlemede yapay sinir ağları yöntemini kullanmışlardır. Çalışmada yapay sinir ağlarının sınıflama fonksiyonundan faydalanılmıştır. Çalışma kapsamında hisseleri İMKB bünyesinde işlem gören tekstil, petrokimya ve plastik sektöründeki şirketlere ait 1998 - 2007 arasındaki bilanço ve gelir tabloları analiz edilmiştir. Elde edilen bulgulara göre kurulan ağ, başarılı şirketlerin %82'sini doğru tahminlemiştir. Ayrıca test grubunda yer alan 10 başarısız işletme de %80 oranında doğru sınıflanmıştır.

Kutlu ve Badur (2009) yaptıkları çalışmada İMKB endeks değerini 2001 – 2006 dönemi için yapay sinir ağları ve hareketli ortalamalar yöntemiyle tahminlemiştir. Çalışma sonucunda elde edilen bulgulara göre kurulan ileri beslemeli yapay sinir ağı İMKB endeksini tahminlemede daha başarılı sonuçlar vermiştir.

Singhal ve Swarup (2011) yaptıkları çalışmada günlük elektrik piyasasında saatlik takas fiyatını üç katmanlı, geriye yayımlı bir yapay sinir ağı modeliyle tahminlemiştir. Çalışmada MAE ve RMSE hata metrikleri kullanılmıştır. Çalışma sonucunda elde edilen bulgulara göre tahmin için kurulan yapay sinir ağı modelinin performansının normal trendli

günlerde, fiyat yükselişinin olduğu günlere göre daha iyi olduğu, ayrıca hafta içi fiyatlarında hafta sonuna nazaran %4 daha yüksek olduğunu göstermektedir.

Altunöz (2013) yaptığı çalışmada bankaların finansal başarısızlıklarının tahmininde yapay sinir ağları yöntemini kullanmıştır. Çalışmada elde edilen sonuçlara göre kurulan model hem başarısızlıktan bir yıl öncesi, hem de başarısızlıktan iki yıl öncesi için yüksek tahmin gücüne sahiptir.

Mombeini ve Yazdani Chamzini (2015) yaptıkları çalışmada altın fiyatını tahminlemede yapay sinir ağları ve Box – Jenkins metodunu karşılaştırmışlardır. Geliştirilen modeller üç ayrı hata metriği (MAE, RMSE, R2) ile sınanmıştır. Elde edilen sonuçlara göre yapay sinir ağları eğitim ve doğrulama kısımlarında Box – Jenkins modelinden daha iyi performans göstermiştir.


Wang vd. (2021) yaptıkları çalışmada Şangay Menkul Kıymetler Borsası Bileşik Endeksi (SSE), Kore Hisse Senedi Fiyat Endeksi (KOSPI), Nikkei225 endeksi (Nikkei225) ve Standart & Poor's 500 endeksi değerlerini Elman sinir ağı modeliyle tahminlemiştir. Çalışmada tahminlemeyi yapması için sekiz ayrı model oluşturulmuştur. Çalışmada Elman sinir ağı modelinde doğrudan giriş – çıkışların modeldeki etkisi analiz edilmiştir. Elde edilen bulgular modelde doğrudan giriş – çıkışlar olduğunda, olmadığı zamana göre daha düşük hata metrikleri elde edildiğini göstermektedir.

Söz konusu çalışmalar ve literatürde yer alan diğer çalışmalar incelendiğinde dolar kurunu çalışmamızda kullanılan girdi değişkenleri ile tahminleyen bir çalışmaya rastlanılmamıştır. Çalışmamızın bu yönüyle de literatüre katkı sunması hedeflenmektedir.

## YÖNTEM

Yapay sinir ağları kantitatif tahminlemede kullanılabilen bir metottur (Türk ve Kiani, 2019: 30). Bu bölümde çalışmada yer alan analizlerde kullanılan yöntem olan yapay sinir ağları yöntemi detaylandırılmıştır.

İnsan beyninde yer alan biyolojik sinir ağının hücreleri olan nöronlar çevreden gelen verileri işlerler. İnsan beyninde yaklaşık olarak 100 milyar nöron bulunmaktadır (Diler, 2003: 65). Yapay sinir ağları insan beyninde yer alan sinir hücreleri olan nöronların çalışma prensibini örnek olarak çalışan yapay zekâ birimleridir. Şekil 1’de örnek bir biyolojik sinir hücresi yapısı (nöron) görülmektedir.




**Şekil 1:** Örnek Bir Biyolojik Sinir Hücresi (Nöron) Yapısı

**Kaynak:** (Vural, 2007: 11)

Nöronlar iletimi tek yönlü sınırlı olan yapılar değildir. Şekilde görülen dentritlerin görevi, kendisinden önce bulunan nörondan gelen veriyi almaktır (Atlı, 2022: 9). Hücre gövdesinin görevi, kendisine iletilen verileri işlemektir, aksonların görevi ise bu verileri diğer nöronların dentritlerine iletilmesini sağlamaktır (Bulut, 2018: 7). Sinapslar ise nöronlar arasında veri alışverişinin gerçekleştirildiği özelleşmiş bölgelerdir (Başpınar, 2006: 18). İnsan yaşı ilerledikçe beyindeki sinaps sayısı azalır. Bir çocuğun beyinde  $10^{16}$  sinaps bulunurken,


yetişkin bir insanın beyinde  $10^{15}$  ve  $5 * 10^{15}$  arası sinaps bulunur (Çelik, 2008: 7). Örnek bir yapay sinir hücresi modeli ise Şekil 2’de görülmektedir.



**Şekil 2:** Yapay Sinir Hücresi

**Kaynak:** (Koç vd., 2004: 3354)

Şekilde  $X_1, X_i, X_n$  değerleri hücreye gelen girdileri ifade etmektedir.  $W_1, W_i, W_n$  değerleri ise girdilere verilen ağırlıkları ifade etmektedir. Eğitimin ardından hücre çekirdeğinde gerçekleştirilen fonksiyon sonrası hücre çıktısı  $y_j$  olarak dışarıya iletilmektedir. Örnek bir yapay sinir ağı modeli Şekil 3’te görülmektedir.



**Şekil 3:** Yapay Sinir Ağı Modeli

**Kaynak:** (Terzi, 2006: 299)

Şekil 3’teki örnek yapay sinir ağı modeli girdi tabakası, gizli tabaka ve çıktı tabakasından oluşmaktadır. Girdi tabakasındaki hücreler gelen veriyi alıp işlemesi için gizli tabakaya aktarılır. Gizli tabakada işlenen veriler dışarıya iletmek üzere çıktı tabakasına gönderilir. Şekil 3’teki örnek yapay sinir ağı modelinde girdi tabakası  $i$  adet hücreden, gizli tabaka  $j$  adet hücreden, çıktı tabakası ise  $k$  adet hücreden oluşmaktadır.



Yapay sinir ağı gelecekte zaman tahmini yanı sıra başka fonksiyonları da gerçekleştirebilme özelliğine sahiptirler. En yoğun uygulama alanı bulan fonksiyonlar sınıflama, veri ilişkilendirme, yorumlama, filtreleme (Ağyar, 2015: 22), izleme, desen tanıma, oluşturma, veri sıkıştırma (Kaya vd., 2005: 96) olarak sıralanabilir.

Yapay sinir ağlarında öğrenme farklı kurallara göre gerçekleştirilmektedir. Bu kurallardan Hebb kuralı, Hopfield kuralı, Kohonen kuralı ve delta kuralı yoğun olarak kullanılan kurallar arasında yer almaktadırlar (Yetkin, 2014: XIX). Hebb kuralı bir öğrenme işlemi sırasında nöronlar arasındaki veri alışverişinin gerçekleştirildiği bölüm olan sinapslar arasında verinin nasıl depolandığını gösterir (Herz vd., 1988: 663). Hopfield (1982) tarafından yapılan çalışmayla geliştirilen Hopfield öğrenme kuralı, ağ elemanları arasındaki bağlantıların kuvvet derecesinin tespit edilmesine dayanmaktadır. Kuvvet derecesi 0 ile 1 arasında değer alan bir öğrenme katsayısı aracılığıyla gerçekleştirilir (Öztemel, 2006: 26). Kohonen (1982) tarafından geliştirilen Kohonen kuralına göre ağda bulunan hücreler ağırlıkları değiştirmek için bir yarış halindedirler. En yüksek değerdeki çıktıyı üreten hücre kazanarak daha kuvvetli hale gelmiştir ve diğer hücrelerin bağlantı ağırlıklarını değiştirebilir (Sevinçtekin, 2014: 24). Delta öğrenme kuralında ise ana hedef çıktı değeri ve gerçek değer arasındaki farkın karesini minimize etmektir (Eğrioğlu vd., 2019: 27). Günümüzde gerçekleştirilen yapay sinir ağı uygulamalarında sıklıkla bu dört eğitim kuralına başvurulmaktadır.

Yapay sinir ağları kullanımını bazı avantajlar ve dezavantajlara sahiptir. Bu avantaj ve dezavantajların bir kısmı Tablo 1’de verilmiştir.

**Tablo 1.** Yapay Sinir Ağları Yönteminin Avantajları ve Dezavantajları**Kaynak:** (Tu, 1996:1229)

Avantajlar	Dezavantajlar
Yapay sinir ağı modelinin eğitimi için az istatistiksel veri gerekir.	Modellerin sahada kullanımı zorluklar barındırabilir.
Modeller girdiler ve çıktılar arasındaki doğrusal olmayan formdaki ilişkileri belirleyebilir.	Ağın modellenmesi daha yüksek bir hesaplama gücünü gerektirebilir.
Değişkenler arasındaki etkileşimleri tespit edebilir.	Yapay sinir ağı modelleri aşırı uyuma meyillidir.
Farklı farklı eğitim algoritmaları kullanılarak eğitim sağlanabilir.	Ağ modeli geliştirme deneyseldir ve bir takım sorunlar çözülmeyi beklemektedir.

## UYGULAMA

Çalışmanın bu kısmında kurulan yapay sinir ağı makroekonomik değişkenlerin 2009 – 2021 verileriyle eğitilmiş ve dolar kurunun aylık ortalama değeri tahminlenerek gerçek verilerle karşılaştırılıp analiz yapılmıştır. Analiz sonrası MSE (Mean Squared Error, Hata Kareleri Ortalaması), MAE (Mean Absolute Error, Mutlak Hata Ortalaması) ve MAPE (Mean Absolute Percentage Error, Mutlak Yüzde Hata Ortalaması) hata metrikleri elde edilmiştir. Çalışmada kullanılan hata metriklerinin formülü şu şekilde ifade edilebilir:

$e_i$  her bir gözlem için hata değeri,  $n$  gözlem sayısı olmak üzere,

$$MSE = \frac{1}{n} \left[ \sum_{i=1}^n (e_i^2) \right] \quad (\text{Shcherbakov vd., 2013:171}).$$

$y'_i$  tahmin değeri,  $y_i$  gerçek değer,  $n$  gözlem sayısı olmak üzere,


$$MAE = \frac{1}{n} \left[ \sum_{i=1}^n (y'_i - y_i) \right] \quad (\text{Lu vd., 2020:5})$$

MAPE değeri, hataların yüzdelik değerinin ortalamasıdır.  $y'_i$  tahmin değeri,  $y_i$  gerçek değer,  $n$  gözlem sayısı olmak üzere  $i$ . gözlem için hatanın yüzdelik değeri ( $HYD_i$ ) ve MAPE şu şekilde formüle edilebilir:

$$HYD_i = \frac{|y'_i - y_i|}{y_i}$$

$$MAPE = \left[ \frac{\sum_{i=1}^n HYD_i}{n} \right] * 100 \text{ (Tayman and Swanson, 1999: 302).}$$

Çalışmanın veri seti yedi farklı makroekonomik değişkenin 2009 – 2021 dönemine ait aylık zaman serilerinden oluşmaktadır. Bu zaman serilerinden dolar kurunun üzerinde etkisi olduğu korelasyon değerleriyle anlaşılması sebebiyle aylık ortalama TÜFE zaman serisi, aylık ortalama bankalar ihtiyaç kredisi faiz oranları zaman serisi, bir ons altının dolar cinsinden aylık ortalama değeri zaman serisi, aylık ortalama BIST100 endeksi zaman serisi, külçe altın aylık ortalama gram fiyatı zaman serisi ve Türkiye Cumhuriyet Merkez Bankası aylık M3 para arzı zaman serisi modelin girdileri olarak kullanılırken, rezerv para olması sebebiyle dolar alış aylık ortalama zaman serisi ise modelin çıktısı olarak kullanılmıştır. Çalışmada Ocak 2009 – Aralık 2021 dönemindeki toplam 156 aya ait aylık veriler kullanılmıştır. 2009 yılı, 2008 yılı sonunda başlayan küresel ekonomik krizin etkilerinin yoğunlaştığı yıl, 2021 yılı ise küresel koronavirüs salgınının etkilerinin yoğun yaşandığı dönem olmuştur. Çalışmada finans piyasalarını etkileyen bu iki küresel olgunun yaşandığı dönemler ve ara dönem ele alınmıştır. Tüm veriler Türkiye Cumhuriyet Merkez Bankası Elektronik Veri Dağıtım Sistemi'nden (EVDS) alınmıştır. Serilere ait grafikler Şekil 4'te, tanımlayıcı istatistikler ise Tablo 2'de verilmiştir. Tanımlayıcı istatistikler ve grafikler E – Views 10 paket programı aracılığıyla elde edilmişlerdir.



Şekil 4: Zaman Serilerine Ait Grafikler

Tablo 2. Zaman Serilerine Ait Tanımlayıcı İstatistikler

	Bankalar Faiz	BIST 100	Gram Altın	M3 Para Arzı	Ons	TÜFE	Dolar
<b>Ortalama</b>	18,54	1.424	170,211	1.505.331.038	1.385,331	297,692	3,562
<b>Medyan</b>	17,33	1.004,5	101,94	1.182.463.121	1.307,455	260,26	2,695
<b>Maksimum Değer</b>	44,879	5.943	817,61	5.275.482.941	1.964,4	686,95	13,53
<b>Minimum Değer</b>	10,608	266,18	44	463.767.530	870,15	160,35	1,42
<b>Standart Sapma</b>	5,574	1.293	142,233	1.036.445.471	256,057	119,381	2,334
<b>Çarpıklık</b>	1,82	2,169	1,792	1,309	0,409	0,956	1,341
<b>Basıklık</b>	7,29	6,633	5,966	4,054	2,301	3,027	4,493
<b>Toplam</b>	2.892,33	222.219	26.553,03	234.367.874.446	216.111,7	46.439,9	555,72

<b>Gözlem Sayısı</b>	156	156	156	156	156	156	156
----------------------	-----	-----	-----	-----	-----	-----	-----

Tüm serilerin çarpıklık ve basıklık katsayıları pozitifdir. Bu durum serilerin sağa çarpık ve sivri bir dağılıma sahip olduklarını göstermektedir. Her seriye ait toplam 156 gözlem değeri bulunmaktadır. Zaman serilerine ait korelasyon değerleri Tablo 3'te verilmiştir.


**Tablo 3.** Zaman Serilerine Ait Korelasyon Tablosu

	<b>Bankalar Faiz Oranı</b>	<b>BIST100</b>	<b>Gram Altın</b>	<b>M3 Para Arzı</b>	<b>Ons</b>	<b>TÜFE</b>	<b>Dolar</b>
<b>Bankalar Faiz Oranı</b>	1						
<b>BIST100</b>	0,250559	1					
<b>Gram Altın</b>	0,324221	0,934939	1				
<b>M3 Para Arzı</b>	0,336037	0,924926	0,982555	1			
<b>Ons</b>	0,014069	0,638434	0,659760	0,580090	1		
<b>TÜFE</b>	0,376368	0,885033	0,957055	0,990507	0,54386	1	
<b>Dolar</b>	0,407593	0,890053	0,977447	0,990266	0,53361	0,9867	1

Korelasyon tablosu incelendiğinde tüm seriler arasında pozitif korelasyon görülmektedir. Bununla beraber en zayıf ilişki 0,014069 korelasyon değeri ile aylık ortalama ons altın fiyatı ve bankalar aylık ortalama faiz oranı arasında bulunurken, en güçlü ilişki ise 0,990507 korelasyon değeri ile aylık M3 para arzı ve aylık TÜFE oranı arasında tespit edilmiştir.


Yapay sinir ağları yöntemi, analiz öncesi herhangi bir ön varsayımı gerektirmezler (Aktaş vd., 2003: 11). Dolayısıyla veriler analiz öncesi herhangi bir ön işleme tabi tutulmamışlardır. Kurulan yapay sinir ağı modelinde literatürdeki tahmin çalışmalarında yoğunlukla tercih edilen ileri beslemeli geri yayımlı ağ tipi ve çok katmanlı algılayıcı kullanılmıştır. Hücre sayısı ve katman sayısı gibi faktörler deneme – yanılma yöntemiyle belirlenmiştir. Yapılan denemelerde en düşük MSE değerini veren model tercih edilmiştir. Model eğitiminde TRAINLM (Levenberg – Marquardt) ve LEARNNGDM (Momentum Ağırlıklı Öğrenme) fonksiyonları kullanılmıştır. Model aktivasyonunda ise modele doğrusal olmayan bir yapı kazandıran TANSIG (Tanjant Hiperbolik) fonksiyonu tercih edilmiştir. Kurulan ağa en düşük MSE

değerini bulabilmek amacıyla 1000 ayrı deneme yapma talimatı verilmiştir. Şekil 5’te kurulan ağa ait temsili yapı görülmektedir.



Şekil 5: Kurulan Ağa Ait Temsili Yapı

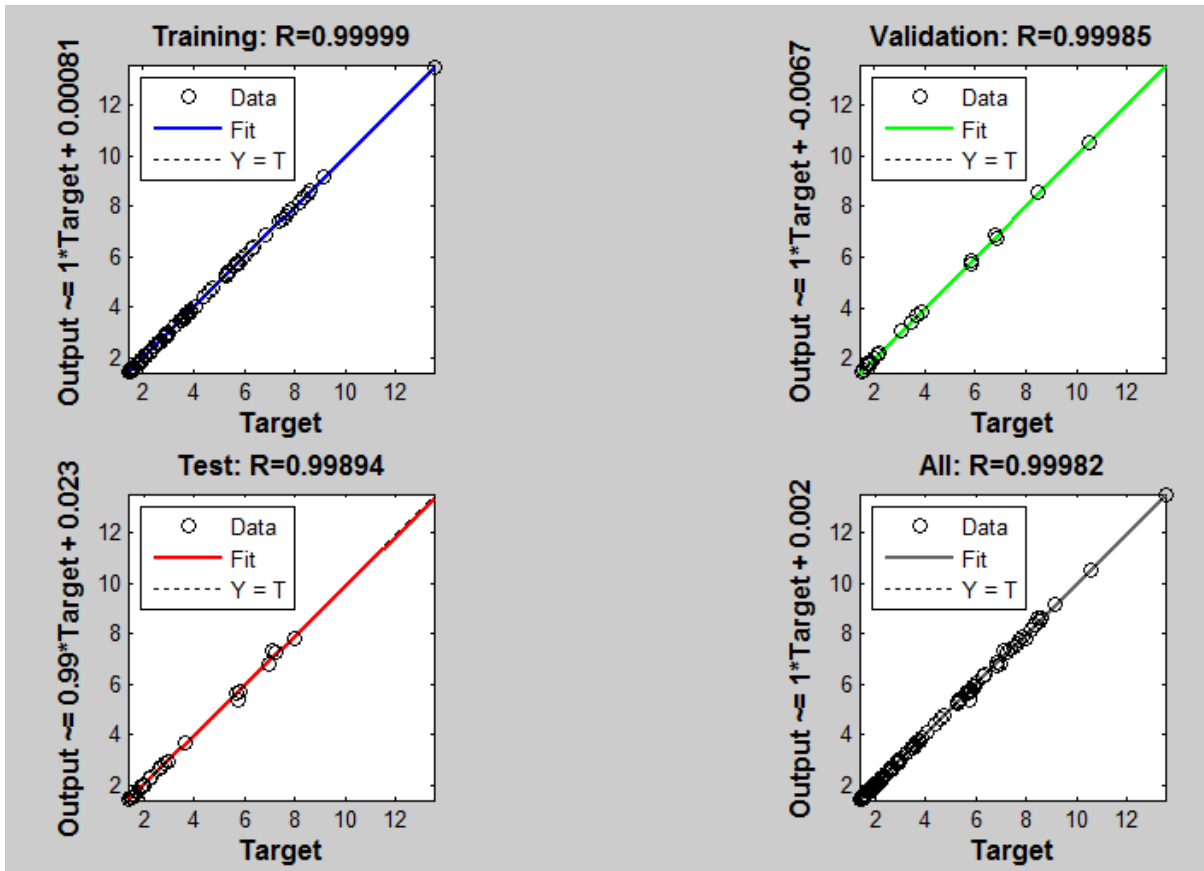
Kurulan ağ, bir gizli katman (Hidden layer) ve bir de çıkış katmanından (Output layer) oluşmaktadır. Altı adet girdi ve bir adet çıktı bulunmaktadır. Gizli katmanda 10 adet nöron, çıktı katmanında ise bir adet nöron bulunmaktadır. “w” ifadesi ağırlık katsayılarını, “b” ifadesi ise değişken katsayılarını ifade etmektedir. Şekil 6’da kurulan ağa ait performans grafiği verilmiştir.



Şekil 6: Kurulan Ağa Ait Performans Grafiği


Şekilde yatay eksen deneme sayısını, dikey eksen ise MSE değerini göstermektedir. Yeşil daire içine alınan bölüm doğrulama grubuna ait en düşük MSE değerinin yakalandığı denemeyi göstermektedir. Buna göre kurulan ağ, 557. Denemede 0,0019355 ile en düşük MSE değerini

elde etmiştir. Şekil 7’de eğitim, doğrulama, test grupları ile tüm veri grubuna ait regresyon grafikleri görülmektedir.



Şekil 7: Regresyon Grafikleri

Regresyon grafikleri incelendiğinde her dört gruba ait regresyon değerlerinin 1’e çok yakın olduğu gözlemlenmektedir. Bu bulgu kurulan modelin başarılı eğitim ve tahmin performansını ifade eder. Şekil 8’de tüm seri için tahmin edilen değerler ve gerçek değerlere ait grafik verilmiştir. Grafikte yatay eksen dönemleri, dikey eksen ise değerleri ifade ederken; mavi hat gerçek değerleri, turuncu hat ise tahmin değerlerini göstermektedir.



**Şekil 8:** Gerçek Değerler ve Tahmin Değerleri Grafiği

Kurulan model ve bu modelle yapılan tahmin sonuçları sonrası elde edilen hata metriği değerleri Tablo 4’te verilmiştir.

**Tablo 4:** Oluşan Hata Metriği Değerleri

MSE	MAE	MAPE
0,0019355	0,01738	0,5137

156 aylık dönemin tahmini sonrası MSE değeri 0,0019355, MAE değeri 0,01738, MAPE değeri ise 0,5137 olarak oluşmuştur. MAPE değeri modelin ortalama mutlak yüzde hatasını ifade etmektedir. Model % 0,5137 hata ile dolar kurunu tahminlemiştir. MAPE değerinin %10’dan düşük olması yüksek isabet oranını gösterir (Shehadeh vd., 2021: 14). Kurulan model dolar kurunu tahminlemede yüksek derecede doğruluk göstermiştir.



## SONUÇ ve ÖNERİLER

Dolar, Bretton Woods anlaşmasıyla rezerv para olarak kabul edilmesi ve tüm dünyada en yüksek geçerliliğe sahip para birimi olması gibi özellikleriyle yatırımcıların yoğun olarak ilgi gösterdiği bir finansal enstrümandır. Bu özellikleriyle ilerleyen dönemlerde alacağı değerler literatürde çeşitli nicel tahmin yöntemleriyle tahminlenmeye çalışılmıştır. Bu çalışmada da “Yapay sinir ağı yöntemi dolar kurunu tahminlemede başarılı bir yöntem midir?” sorusuna cevap aranmıştır. Dolar kuru yapay sinir ağı yöntemiyle, altı farklı makroekonomik değişkenin girdi olarak kullanıldığı model kurularak tahminlenmiştir. Bu girdi değişkenleri bir ons altının dolar cinsinden aylık ortalama değeri, Türkiye Cumhuriyet Merkez Bankası aylık ortalama M3 para arzı, külçe altın aylık ortalama gram fiyatının Türk Lirası cinsinden değeri, aylık TÜFE düzeyi, aylık ortalama BIST100 endeksi düzeyi, aylık ortalama bankalar ihtiyaç kredisi faiz oranları değişkenleridir. Aylık ortalama dolar kuru ise modelin çıktısıdır.

Tahminleme için bir gizli katman ve bir de çıktı katmanından oluşan iki katmanlı bir yapay sinir ağı modeli tasarlanmıştır. Tasarlanan modelin yaptığı 156 aya ait tahminleme sonrası gerçek değerler ve tahmin değerleri karşılaştırılarak hata metrikleri hesaplanmıştır.

Hata metriği olarak literatürdeki tahminleme çalışmalarında yoğunlukla tercih edilen MSE, MAE ve MAPE hata metrikleri tercih edilmiştir. MSE değeri 0,0019355, MAE değeri 0,01738, MAPE değeri ise 0,5137 olarak hesaplanmıştır. MAE değeri mutlak ortalama hatayı, MSE değeri hata karelerinin ortalamasını ifade etmektedir. MAPE ise modelin yüzde kaç hata ile tahminleme yaptığını gösteren metriktir. Literatürde %10'dan düşük olan MAPE değerinin olduğu tahminlemeler yüksek performans gösterilen tahminlemeler olarak sınıflandırılmaktadırlar. Elde edilen sonuçlara göre model % 0,5137 hata ile tahminleme yaparak oldukça yüksek bir performans göstermiştir. Çalışma sonucunda elde edilen bulgular yapay sinir ağı yönteminin aylık ortalama dolar kurunu tahminlemede ideal bir yöntem olduğunu göstermektedir.

Yapay sinir ağılar eğitim için geleneksel yöntemlere nazaran daha yüksek sayıda veriye ihtiyaç duyarlar (Yüksel ve Akkoç, 2016: 48). Kurulan yapay sinir ağı modelinin eğitimi sonrası oluşan regresyon değerleri model eğitiminde yüksek başarı sağlandığını göstermektedir. Eğitimde sağlanan yüksek başarı tahmin performansını da yukarı çekerek başarılı tahminlemeler yapılmasını sağlamıştır. Tahmin performansının yüksek olması aynı zamanda model kurulumunda seçilen bağımsız değişkenlerin seçiminde doğru tercihlerin yapıldığını da göstermektedir. Yapay sinir ağılar ile ileride yapılacak olan döviz kuru tahminleme çalışmalarında benzer makro ekonomik değişkenlerin model girdisi olarak kullanılması önerilmektedir.

## KAYNAKÇA

- Ağyar, Z. (2015). Yapay sinir ağlarının kullanım alanları ve bir uygulama. *Mühendis ve Makine*, 56(662), 22-23.
- Akkaya, G. C., Demireli, E. & Yakut, Ü. H. (2009). İşletmelerde finansal başarısızlık tahminlemesi: Yapay sinir ağları ile İMKB üzerine bir uygulama. *Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Dergisi*, 10(2), 187-216.
- Aktaş, R., Doğanay, M. M. & Yıldız, B. (2003). Mali başarısızlığın öngörülmesi: İstatistiksel yöntemler ve yapay sinir ağı karşılaştırılması. *Ankara Üniversitesi Siyasal Bilgiler Fakültesi Dergisi*, 58(4), 1-24.
- Altunöz, U. (2013). Bankaların finansal başarısızlıklarının yapay sinir ağları modeli çerçevesinde tahmin Eedilebilirliği. *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 28(2), 189-217.
- Atlı, D. F. (2022). *Yapay sinir ağlarının eğitimi için salp sürü optimizasyonu algoritmasının iyileştirilmesi* (Tez No. 743583) [Yüksek Lisans Tezi, Necmettin Erbakan Üniversitesi].
- Başpınar, U. (2006). *PIC mikrodenetleyici ile yapay sinir ağı donanım modülü* (Tez No. 185234) [Yüksek Lisans Tezi, Marmara Üniversitesi].
- Bulut, C. (2018). *Beyin bilgisayar arayüzü uygulamaları için EEG sinyal analizi* (Tez No. 507466) [Yüksek Lisans Tezi, Altınbaş Üniversitesi].
- Çelik, B. (2008). *Yapay sinir ağları metodolojisi ile zaman serisi analizi: Teori ve uygulama* (Tez No. 227201) [Yüksek Lisans Tezi, Marmara Üniversitesi].
- Diler, A. İ. (2003). “İMKB Ulusal – 100 endeksinin yönünün yapay sinir ağları hata geriye yayma yöntemi ile tahmin edilmesi”, *İMKB Dergisi*, 7(25-26), 65-81.
- Eğrioğlu, E., Yolcu, U. & Baş, E. (2019). *Yapay sinir ağları öngörü ve tahmin uygulamaları*. Nobel Yayıncılık.

- Ekin, E. & Akdoğan, Ö. Ç. (2018). Yapay sinir ağları ve monte carlo tree search algoritması ile tavla oyunu uygulaması. *Social Sciences Research Journal*, 7(2), 246-261.
- Hebb, D.O. (1949). *The organization of behaviour a neuropsychological theory*. John Wiley & Sons.
- Herz, A., Sulzer B., Kühn, R. & Van Hemmen, J.L. (1988). The Hebb rule: Storing static and dynamic objects in an associative neural network. *Europhysics Letters*, 7(7), 663-669.
- Hopfield, J. J. (1982). Neural networks and physical systems with emergent collective computational abilities. *Proceedings of the National Academy of Sciences*, 79(8), 2554-2558.
- Jain, A. K. & Mao, J. (1996). Artificial neural networks: A tutorial. *Computer*, 29(3), 31-44.
- Kargül, İ. D. (2011). Günümüzde rezerv para. *Istanbul Journal of Sociological Studies*, (43), 139-142.
- Kaya, İ., Oktay, S. ve Engin, O. (2005). Kalite kontrol problemlerinin çözümünde yapay sinir ağlarının kullanımı. *Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 21(1-2), 92-107.
- Koç, M. L., Balas, C. E. & Arslan, A. (2004). Taş dolgu dalgakıranların yapay sinir ağları ile ön Tasarımı. *Teknik Dergi*, 15(74), 3351-3375.
- Kohonen, T. (1982). Self-organized formation of topologically correct feature maps. *Biological Cybernetics*, 43(1), 59-69.
- Krogh, A. (2008). What are artificial neural networks?. *Nature Biotechnology*, 26(2), 195-197.
- Kutlu B. & Badur B. (2009). Yapay sinir ağları ile borsa endeksi tahmini. *Yönetim Dergisi*, 20(63), 25-40.
- Lu, W., Li, J., Li, Y., Sun, A. & Wang, J. (2020). A CNN – LSTM – based model to forecast stock prices. *Complexity*, 1-10.

- McCulloch, W. S. & Pitts, W. H. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115-133.
- Mombeini, H. & Yazdani Chamzini, A. (2015). Modeling gold price via artificial neural network. *Journal of Economics Business and Management*, 3(7), 699-703.
- Öztemel, E. (2006). *Yapay Sinir Ağları*. Papatya Yayıncılık.
- Roh, T. H. (2007). Forecasting the volatility of stock price index. *Expert Systems with Applications*, 33(4), 916-922.
- Rosenblatt, F. (1958). The perceptron: A probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386.
- Saatçioğlu, D. & Özçakar, N. (2016). Yapay sinir ağları yöntemi ile aralıklı talep tahmini. *Beykoz Akademi Dergisi*, 4(1), 1-32.
- Sevinçtekin, E. (2014). *İmalat sektöründe yapay sinir ağları uygulaması* (Tez No. 364178) [Yüksek Lisans Tezi, Yıldız Teknik Üniversitesi].
- Shcherbakov, M. V., Brebels, A., Shcherbakova, N. L., Tyukov, A. P., Janovsky, T. A. & Kamaev, V. A. (2013). A survey of forecast error measures. *World Applied Sciences Journal*, 24(24), 171-176.
- Shehadeh, A., Alshboul, O., Al Mamlook, R. E. & Hamedat, O. (2021). Machine learning models for predicting the residual value of heavy construction equipment: An evaluation of modified decision tree, LightGBM and XGBoost regression. *Automation in Construction*, 129, 1-16.
- Singhal, D. & Swarup K.S. (2011). Electricity price forecasting using artificial neural networks. *Electrical Power and Energy Systems*, 33(3), 550-555.
- Tayman, J. & Swanson, D. A. (1999). On the validity of MAPE as a measure of population forecast accuracy. *Population Research and Policy Review*, 18(4), 299-322.

- Tektaş, A. & Karataş, A. (2004). Yapay sinir ağları ve finans alanına uygulanması: Hisse senedi fiyat tahminlemesi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18(3-4), 337-349.
- Terzi, Ö. (2006). Yapay sinir ağları metodu ile Eğirdir Gölü su sıcaklığının tahmini. *Süleyman Demirel Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 10(2), 297-302.
- Tkacz, G. (2001). Neural network forecasting of Canadian GDP growth. *International Journal of Forecasting*, 17(1), 57-69.
- Tu, J. V. (1996). Advantages and disadvantages of using artificial neural networks versus logistic regression for predicting medical outcomes. *Journal of Clinical Epidemiology*, 49(11), 1225-1231.
- Türk, E. & Kiani, F. (2019). Yapay sinir ağları ile talep tahmini yapma: Beyaz eşya üretim planlaması için YSA uygulaması. *İstanbul Sebhattin Zaim Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 1(1), 30-37.
- Vural, B. B. (2007). *Yapay sinir ağları ile finansal tahmin* (Tez No. 208211) [Yüksek Lisans Tezi, Ankara Üniversitesi].
- Wang, Y., Wang, L., Yang, F., Di, W. & Chang, Q. (2021). Advantages of direct input - to - output connections in neural networks: The Elman network for stock index forecasting. *Information Sciences*, 547, 1066-1079.
- Yetkin, M. (2014). *Tanker Şamandıra Bağlama Sistemlerinin Yapay Sinir Ağları Tekniğiyle Optimizasyonu* (Tez No. 419525) [Yüksek Lisans Tezi, İstanbul Teknik Üniversitesi].
- Yüksel, R. & Akkoç, S. (2016). Altın fiyatlarının yapay sinir ağları ile tahmini ve bir uygulama. *Doğuş Üniversitesi Dergisi*, 17(1), 39-50.