



## YAPAY SİNİR AĞLARI İLE BIST-100 ENDEKS DEĞERİNİN TAHMİN EDİLMESİ FORECASTING BIST-100 INDEX VALUE WITH ARTIFICIAL NEURAL NETWORKS

Aygülen Kayahan KARAKUL<sup>1</sup>

1. Dr. Öğr. Üyesi, İzmir Katip Çelebi Üniversitesi,  
İktisadi ve İdari Bilimler Fakültesi,  
aygulen.kayahan@ikcu.edu.tr,  
<https://orcid.org/0000-0002-8310-1709>

<b>Makale Türü</b>	<b>Article Type</b>
Araştırma Makalesi	Research Article
<b>Başvuru Tarihi</b>	<b>Application Date</b>
17.04.2020	04.17.2020
<b>Yayına Kabul Tarihi</b>	<b>Admission Date</b>
05.07.2020	07.05.2020

### DOI

<https://doi.org/10.30798/makuiibf.721866>

### Öz

Bu çalışmanın amacı Yapay Sinir Ağları'nın finans alanındaki tahmin problemlerine uygulanabilirliğinin gösterilmesi ve Borsa İstanbul (BIST)-100 Endeksini etkileyen değişkenler arasındaki ilişkilerin modellenmesidir. Çalışmada BIST-100 Endeksi, Gecelik Faiz Oranları ve Dolar Kuru arasındaki ilişkiler ileri beslemeli, geriye yayımlı Çok Katmanlı Algılayıcı (Multi-Layered Perceptron-MLP) kullanılarak Yapay Sinir Ağları ile modellenmiş ve BIST-100 Endeks değeri tahmin edilmiştir. Çalışmada 4 Ocak 2010 ile 7 Ocak 2020 arasındaki 2511 iş gününe ait veriler Türkiye Cumhuriyet Merkez Bankası Elektronik Veri Dağıtım Sisteminden alınmıştır. Veri setinin % 90'ı eğitim, % 10'u test verileri olarak ayrılmış ve MATLAB 2020a ile veriler analiz edilmiştir. Çeşitli eğitim, aktivasyon ve transfer fonksiyonları arasından en uygun olanları veri seti üzerinde yapılan denemeler ile belirlenmiş, sonrasında çeşitli mimarideki modeller kurulmuş; modellerin tahmin başarıları, tahmin değerler ile gerçek veriler arasındaki regresyon ilişkisi ile belirlenmiştir. Kurulan modeller ile eğitilen ağların test verileri üzerindeki simülasyonu sonrasında modellerin performansları Ortalama Mutlak Yüzde Hata (Mean Absolute Percentage Error-MAPE) değeri kullanılarak yapılmıştır. Elde edilen sonuçlara göre değişkenler arasındaki ilişkileri modelleyen ve en iyi performansı gösteren ağ, mimarisi 2-10-10-1 olan iki gizli katmanlı, her gizli katmanında 10'ar nöronu olan ağıdır. Böylece Yapay Sinir Ağlarının finans alanındaki tahmin problemlerine uygulanabilir olduğu görülmüştür.

**Anahtar Kelimeler:** *Yapay Sinir Ağları, Tahmin Modeli, BIST-100 Endeksi,*

### Abstract

The aim of this research is to apply Artificial Neural Networks in finance problems as well as to model the relationships between variables that effect the Stock Market of Turkey:Borsa Istanbul. The relationship between BIST-100 index, Overnight Interest Rates and Exchange Rate of Dollar modelled by using feed-forward back propogation Multilayer Perceptron(MLP) of Artificial Neural Networks and BIST-100 index value is estimated. The data is taken from Turkish Republic Central Bank Electronic Data Distribution system. 2511 data between 4 January 2010 and 7 January 2020 of working days has been used. The % 90 of data set is used for training, % 10 is used for testing. MATLAB 2020a is used for analysis. Many training, activation and transfer functions under many architectures are used to establish the most robust model. The performance is measured by the regression relationship between the exact values and estimated values. The forecasting performance of simulation of networks on test data is measured by Mean Absolute Percentage Error-MAPE. According to the results the best performed neural network that models the relationship between variables has 2 hidden layers, with 10 neurons in each hidden layer and has the architecture 2-10-10-1. Therefore Artificial Neural Networks can be used in the forecasting problems of financial issues.

**Keywords:** *Artificial Neural Networks, Forecasting Model, BIST-100 Index,*

## EXTENDED SUMMARY

### Research Problem

This research has been conducted to forecast the Stock Market index of Turkey-Borsa Istanbul (BIST) 100 index, by using an advanced technique: Artificial Neural Networks (ANNs).

### Research Questions

The questions of research are listed as follows: Is it possible to use ANNs for forecasting the BIST-100 Index of Turkey? Is it possible to model the relationships between variables BIST-100 Index, Exchange Rate of Dollar and the overnight interest rates? If it is possible to model the patterns between those variables is it possible to improve the model and find the best model by using the training and learning capabilities of ANN.

### Literature Review

Prediction is a part of science which enables to foresee the future. Forecasting and modelling studies on Stock Markets enable to reduce the uncertainties about the future, so that the businesses can make true investment decisions (Usul, Küçüksille ve Karaođlan, 2017). The importance of the financial studies requires to use advanced forecasting techniques. ANN which is a sub branch of Artificial Intelligence, can learn from a sample of data, keep the learned knowledge and use this knowledge in a sample of data that was not seen before, as well as it does not require any pre assumption. ANNs are used in many fields mostly in signal processing, predicting and clustering as nonlinear, multi-layered parallel regression techniques such as function approximation, pattern matching, data clustering, classification and conceptualization, finding out parameters, accumulating knowledge through training, application of a prior knowledge of the connection weights, adding knowledge in a neural network structure for the purpose of Approximate Reasoning (Shanmuganathan, 2016:8-9). So this advanced technique, ANN, is the best method to use in forecasting in the financial aspects, like predicting the Stock Market index value.

### Methodology

ANN enables to model the non linear relationships without any restriction as controversy to those in the conventional statistical methods. ANN is a modelling method that simulates the biological neurons in a nervous system of a human being with the help of the learning algorithms and activation functions as in the cognitive functions of nervous system. The degree of accuracy of model can be calculated with the Coefficient of Determination or Correlation Coefficient and the forecasting performance of network is determined by the Mean Absolute Percentage Error (MAPE). The dataset in the research consisting of 2511 days' data, is obtained from the official website of Turkish Republic Central Bank. Independent variables are exchange rate of Dollar and overnight interest rates which are determined by a literature review on Stock Market index prediction. The dependent variable is the BIST-100 index value. The feed forward and back propagation Multilayered Perceptron (MLP) is used to construct a model between variables. Training, activation and learning algorithms are changed in each experiment to find the best

fit, then the trained networks are simulated on the testing data and the performance of networks are compared with MAPE.

### **Results and Conclusions**

The dataset is divided into two sets as training and testing sets as 90 % and 10 % respectively. The best neural network model is searched on the training set and the trained networks are simulated on the testing set. The best model between variables has been set up by using the learning capabilities of ANNs. By changing the learning, training and activation functions in 16 experiments the best ones are selected. 8 different models has been set up and 2 of them has been eliminated according to the Regression results in MATLAB 2020a. The best model is selected between the rest ones by changing the hidden layers and neurons in the hidden layers. The trained networks are simulated on the test data. The performance of models has been compared with Mean Absolute Percentage Error- MAPE. As a result the best model has an architecture of 2-10-10-1 with 2 hidden layers and 10 neurons in each hidden layers. The MAPE is observed as 7,91 % . It is obtained that ANN can be successfully used to forecast the BIST-100 index value.

## 1. GİRİŞ

Yapay Zekâ, insan beyninin çalışma esasının matematiksel olarak modellenmesi fikrinden doğmuştur. Bu fikir “sinir sisteminin merkezindeki beyin, biyolojik sinir ağları ile sürekli olarak bilgiyi alıp, işleme ve sinir ağları içinden çıkan sonuçlara göre uygun kararları vermesi” (Haykın, 2009, 36) durumunun benzetimidir. Yapay Sinir Ağları (YSA) biyolojik nöronların çeşitli bilgilerin depolandığı birimlerden sinyallerle kurdukları ağ yapısı içinde yeni bilgiler karşısında onları sınıflama, gruplama, ayırt etme ve yeniden üretme gibi tepkiler vermesi esasına dayanır. YSA sayesinde biyolojik sinir ağlarının anlama, anlamlandırma ve öğrenme özellikleri matematiksel olarak modellenebilmekte, böylece bir veri setinin değişkenleri arasındaki ilişkiler çeşitli fonksiyonlar ve algoritmalar yardımıyla genel bir ağ yapısı olarak ifade edilebilmektedir.

İnsan zekâsının bir taklidi olarak kurgulanan Yapay Zekânın alt bileşeni olan yöntemler sadece doğa bilimlerinde değil, aynı zamanda sosyal bilim alanlarında da sıklıkla kullanılabilir. Bugün gelinen noktada bu yöntemler tıbbi görüntüleme teknolojileri, hastalık nedenlerinin belirlenmesi, genetik kan ve örnekleme haritalarının oluşturulması, (Kattan, Abdullah, & Geem, 2011: 5-6; Haykın, 1999), savunma sanayisinde uçuş yörüngelerinin belirlenmesi, robotik sistemlerin geliştirilmesi gibi mühendislik projelerinde ve doğa bilimleri alanlarında olduğu kadar, aynı zamanda makroekonomik tahminler, sigorta risk analizi, stok yatırım analizi, banka kredilerinin değerlendirilmesi, üretim yönetimi, kalite analizi, otomasyon sistemlerinin geliştirilmesi, üretim birimlerinin optimizasyonu gibi iktisadi konularda ve sosyal bilim alanlarında da kullanılmaktadır (Haykın, 1999).

Hisse senedi piyasası, ülke ekonomilerinin önemli göstergelerinden biri olup, bu piyasanın bileşenleri arasındaki ilişkiler birçok çalışmada araştırılmıştır. Hisse senedi piyasasında yapılacak tahmin ve modelleme çalışmaları, geleceğe dönük belirsizliklerin azaltılmasını sağlayacak ve böylece işletmelerin yatırım konularında doğru kararlar almasına yardımcı olacaktır (Usul, Küçüksille ve Karaoğlan, 2017). Bu araştırmanın amacı YSA'nın finans alanına uygulanabilirliğinin incelenmesi ve bu yolla Borsa İstanbul (BIST) Endeks değerinin tahmininin yapılmasıdır. İyi finansal tahmin modellerinin kurulması, finansal piyasalarda iyi kararlar verilmesini sağlayacaktır. Çalışmanın bundan sonraki bölümleri şu şekilde oluşturulmuştur: Birinci bölümde daha önce yapılmış benzer çalışmalara yer verilmiş, İkinci bölümde araştırmanın yöntemi olarak seçilen YSA ile modelleme verilmiş, üçüncü bölümde araştırmanın bulguları, dördüncü bölümde de sonuçları verilmiştir.

## 2. LİTERATÜR

YSA, finans alanında borsa verileri üzerinde birçok tahmin probleminde kullanılmıştır. Bu bölümde konu alanı olarak finans, yöntem olarak YSA kullanan araştırmalara yer verilmiştir.

Tektaş ve Karataş (2004) araştırmalarında gıda ve çimento alanlarında faaliyet gösteren ve hisse senetleri İMKB'de işlem gören, 7 şirketin hisse senedi fiyatlarını tahmin etmeyi amaçlamışlar, YSA ve çoklu regresyon tekniklerini haftalık ve günlük verilerden oluşan iki veri seti üzerinde kullanmışlardır.

Haftalık verilerde bağımlı değişken olarak şirketlerin Cuma günkü hisse senedi kapanış fiyat bilgisini, bağımsız değişkenler olarak aylık enflasyon endeksi, bir aylık mevduat faiz oranları, IMKB-100 Endeksi, IMKB Sınai Endeksi ve Dolar Kurunu kullanmışlardır. Günlük verilerde ise bağımlı değişken olarak günlük hisse senedi kapanış fiyatı, bağımsız değişkenler olarak Dolar Kuru, IMKB-100 Endeksi ve IMKB Sınai Endeksini kullanmışlardır. Tahmin performansı olarak gerçek ve tahmin veriler arasındaki korelasyon katsayısını dikkate almışlardır. Elde ettikleri sonuçlar, günlük ve haftalık veriler üzerinde uygulanan YSA'lar arasından günlük verilerin kullanıldığı ağ yapılarının daha başarılı olduğunu; günlük veriler üzerindeki regresyon ve YSA arasından ise YSA yönteminin daha başarılı olduğunu göstermektedir.

Kutlu ve Badur (2009) Borsada önceki günün kapanış fiyatını tahmin etmeyi amaçlamışlardır. Araştırmacılar kurdukları üç modelde farklı bağımsız değişkenler kullanmışlardır. Birinci modeldeki bağımsız değişkenler Dolar Kuru ve gecelik faiz değerleri, ikinci modeldekiler birinci modeldekilere ek olarak haftanın günleri, üçüncü modeldekiler de ikinci modeldekilere ek olarak farklı 7 ülkedeki borsa endeksi değerleridir. Model performanslarını belirlemek için R2 değerini kullanmışlardır. Elde ettikleri sonuçlara göre en yüksek performansa sahip model en az sayıda bağımsız değişkeni içeren birinci modeldir. Böylece daha çok sayıda bağımsız değişkenin her zaman daha iyi bir tahmin performansı sergileyeceği düşüncesinin yanlıtıcılığı ortaya çıkmıştır.

Merh, Saxena ve Pardasani (2011) araştırmalarında Bombay Borsası'na kayıtlı olan 30 şirketin hisse senedi fiyat endeksi olan Sensex Endeks değerini tahmin etmeyi amaçlamışlardır. Çalışmalarında her günün açılış değeri, en yüksek değeri, en düşük değeri ve kapanış değerini bağımsız değişken olarak ele alıp bir sonraki günün değerini YSA ve ARIMA yöntemleri ile tahmin etmişlerdir. Tahmin performanslarını AAE (Average Absolute Error- Ortalama Mutlak Hata), RMSE (Root Mean Square Error-Hataların Ortalama Karekökü), MAPE (Mean Absolute Percentage Error-Ortalama Mutlak Yüzde Hata) ve MSPE (Mean Square Percentage Error-Ortalama Karesel Yüzde Hata) ile karşılaştırdıklarında ARIMA ile kurulan model performansının daha iyi olduğunu belirtmişlerdir.

Akcan ve Kartal (2011) İMKB-Sigorta Endeksini oluşturan 7 şirketin hisse senedi fiyatlarını Yapay Sinir Ağları ile tahmin etmeyi amaçlamışlardır. Araştırmacılar çalışmalarında 4 makro ekonomik değişken ve 8 mikro ekonomik değişkeni bağımsız değişkenler olarak kullanmışlardır. 2009 ve 2011 yılları arasındaki 508 işgünü verisini % 70 ve % 30 oranlarında eğitim ve test verileri olarak ayırmışlar, kurdukları modellerin performanslarını MAE (Mean Absolute Error-Ortalama Mutlak Hata) ve MAPE ile karşılaştırmışlar, YSA'nın tahmin performansının daha iyi olduğunu bulmuşlardır.

Güresen, Kayakutlu ve Daim (2011) Amerika'daki NASDAQ Borsası endeks değerini tahmin etmeyi amaçladıkları çalışmalarında farklı YSA modellerini kullanmışlardır. Çok Katmanlı Algılayıcı, Ghiassi & Saidane (2005) tarafından geliştirilen Dinamik YSA ve Roh (2007) tarafından geliştirilen hibrit YSA modellerinin tahmin performanslarını karşılaştırmışlardır.

Yakut, Elmas ve Yavuz (2014) çalışmalarında BIST Endeks Değerini tahmin etmeye çalışmışlar, çalışmalarında Kutlu ve Badur'un (2009) çalışmalarında ele aldıkları değişkenlere ek olarak

iki ve üç gün önceki BIST Endeksi değerlerini ekleyerek 9 farklı model kurmuşlardır. Modelleri üzerinde YSA ve vektör destek makineleri yöntemlerini uygulamışlardır. Performans ölçütü olarak ele aldıkları R2 değeri çalışmalarında 0,91 ile 0,97 arasında değişmektedir. YSA yöntemi kullandıklarında tahmin performansı açısından en başarılı modeller bir önceki günün endeks değerini tahmin eden Dolar Kuru, faiz oranı modeli ile yine bir önceki günün endeks değerini tahmin eden Dolar Kuru, faiz oranı ve haftanın günleri değişkenlerinden oluşan modellerdir.

Çalışkan ve Deniz (2015) BIST-30 endeksinde yer alan verilerini elde edebildikleri 27 şirketin hisse senedi fiyatlarını ve fiyat yönünü tahmin etmeyi amaçlamışlardır. Girdi değişkenleri olarak şirketlerin günlük en yüksek, en düşük, kapanış fiyatlarını, günlük getiri oranlarını ve 5 günlük ortalama fiyat değerlerini almış, ayrıca her hisse senedi için aynı olan BIST 100 değeri, Dolar Kuru, altın fiyatları gibi değişkenleri kullanmışlardır. Bir gizli katmanlı, gizli katmanında 50 nöron içeren bir ağla yaptıkları tahminde 27 şirket için MAPE değerlerini 7 şirket dışında % 2'nin altında bulmuşlardır.

Moghaddam A.H, Moghaddam, M.H ve Esfandyari (2016) YSA kullanarak Amerika'daki NASDAQ Borsası'nın endeks değerini iki farklı türdeki girdi kümesi ile tahmin etmeye çalışmışlardır. 70 günlük veriyi eğitim seti olarak, 29 günlük veriyi test seti olarak ayırmışlardır. İlk olarak dört gün önceki değerleri ve haftanın günlerini kullanmışlar, ikinci olarak dokuz gün önceki değerleri ve haftanın günlerini kullanmışlardır. Farklı eğitim ve transfer fonksiyonları ile farklı gizli katman ve gizli katman içindeki farklı nöron sayıları ile oluşturdukları modellerin performanslarını R2 ve MSE (Mean Square Error- Ortalama Karesel Hata) değerlerini kullanarak karşılaştırmışlardır.

### 3. ARAŞTIRMA YÖNTEMİ VE MODELİ

Yapay Sinir Ağları tıpkı insanlar gibi deneyimler yaşadıkça öğrenir ve bunu, belirli öğrenme algoritmaları kullanarak gerçekleştirir. Ağın öğrendiği bilgiler, daha önce ağ tarafından kullanılmamış olan veri setleri üzerinde uygulanır. YSA'lar işaret işleme, örüntü eşleme, veri kümeleme, fonksiyon yakınsaması sureti ile sınıflandırma ve tahmin problemlerinde kullanılır. Ayrıca ağın eğitilmesi sonucunda oluşan bağlantı ağırlıklarının öncel bilgisi, bulanık mantık işlemcilerinin genel bir türü olarak ifade edilen *Yaklaşık Düşünme (Approximate Reasoning)* amacıyla da kullanılabilir (Shanmuganathan, 2016:8-9).


YSA'lar öğrenme biçimlerine göre danışmanlı (supervised), danışmansız (unsupervised), takviyeli (reinforcement) öğrenme biçimlerine sahip olanlar olarak gruplanabilir. Danışmanlı öğrenmede, ağa girdi ve çıktı değerleri verilir ve ağın bu parametreler arasındaki bağlantı ağırlıklarını öğrenmesi beklenir. Danışmansız öğrenmede girdi değerleri verilerek ağın çıktı değerlerini bulması beklenir. Takviyeli öğrenmede ise girdiler verilerek iyi çıktılar sağlandığında bağlantı ağırlıkları ödüllendirilir, kötü çıktılar sağlanırsa ağırlıklar cezalandırılır (Shanmuganathan, 2016:8).

Mimarisine göre YSA'lar belirli (deterministic) ve belirsiz (stochastic) YSA'lar olarak gruplanır. Sinir ağlarının işaretinin akış yönüne göre, ileri beslemeli (feedforward) ve geri beslemeli (feedback) olarak gruplanır. Giriş katmanından çıkış katmanına doğru, işaretlerin yalnız bir yönde



ilerlediği ağa ileri beslemeli ağ, bir sinirin çıkışından girişine işaretin ulaştığı ağa geri beslemeli ağ denir (Nabiyev, 2016:587).

**Şekil 1.** Bir Biyolojik Nöron ve Bir Yapay Sinir Ağı



**Kaynak:** Kattan, Abdullah, & Geem (2011)

YSA, nöron adı verilen pek çok işlemci elemandan oluşmaktadır. Nöronlar birbirine belirli ağırlıklar atanmış olan birleştirme mekanizmaları ile birbirine bağlanmaktadır. Değişkenler arasında doğrusal ilişkiler olmadığında Çok Katmanlı Algılayıcı (Multi Layered Perception-MLP) kullanılır (Nabiyev, 2016:602). Bu ağ yapısında girdi, çıktı ve gizli katman olmak üzere üç katman vardır. Nöronlar girdi parametrelerini alıp toplayıp onlara bir sabit (bias) ekleyerek sonrasında transfer fonksiyonu uygulayarak çıktı parametrelerini oluşturur. Matematiksel ifade ile bir P nöronunun;  $x_1, \dots, x_n$  girdi parametreleri ve bağlantı ağırlıkları  $w_{p1}, \dots, w_{pn}$  olmak üzere, girdileri ağırlıklar ile çarpıp toplaması Eşitlik (1)'deki gibi gösterilebilir.

$$u_p = \sum_{i=1}^n w_{pi} x_i \quad (1)$$

Sonrasında oluşan  $u_p$  girdi bileşenlerine, birer katsayı (Bias- $b_p$ ) ekleyerek Eşitlik (2) de  $\varphi$  ile gösterilmiş olan aktivasyon fonksiyonu ile nöronun çıktısı olan  $y_p$ ' ler elde edilir.

$$y_p = \varphi(u_p + b_p) \quad (2)$$

YSA'da Nümerik Analizdeki iterasyon tekniklerine ve optimizasyona dayanan birçok öğrenme algoritması vardır. Bunlardan birisi doğrusal olmayan gerçel değerli fonksiyonların karesi olarak ifade edilebilen çok değişkenli fonksiyonların minimumunu bulmayı sağlayan bir iterasyon tekniği olan LM (Levenberg-Marquardt) algoritmasıdır. (Laurakis, 2005). Bir diğeri Hessian matrisine yakınsayan bir matris dizisini genellemeyi içeren OSS (One Step Secant) algoritmasıdır (Mukkamala, Sung ve Abraham, 2003, s242). Bir diğeri de öğrenme oranını dinamik olarak kendisi ayarlayan GDA (Gradient Descent with Adaptive Learning Rate)'algoritmasıdır.

Aktivasyon fonksiyonları da Threshold (Eşik Değeri Fonksiyonu), Sigmoid (Sürekli Eşikleme Fonksiyonu), Doğrusal Fonksiyon, Katı Sınırlamalı Eşiklendirme Fonksiyonu (signum), Azalan Gradyan (Gradient Descent-GM) ve Momentum ile Azalan Gradyan (Gradient Descent with Momentum-GDM)' dur. Aktivasyon fonksiyonları nöronun aktivasyon düzeyini çıktı sinyaline dönüştürür (Sıby, Jones & Siddarth, 2013).

Transfer fonksiyonları nörondan çıkışı sağlayan fonksiyonlardır. Logaritmik sigmoid (Logsig), Hiperbolik Tanjant sigmoid (Tansig) ve Linear (Purelin) fonksiyonları transfer fonksiyonlarıdır. Logaritmik sigmoid fonksiyonu girdi setini [0,1] aralığına resmeder, türevlenebilir olduğu için MLP’de kullanılabilir. Hiperbolik Tanjant sigmoid fonksiyonu girdi setini [-1,1] aralığına resmeder. Linear olmayan veri seti için idealdir (Dorofki, Elshafie, Jaafar, Karim ve Mastura, 2012).

MLP’de kullanılan öğrenme yöntemlerinden birisi geri yayımlı (back propogation) öğrenmedir. Geri yayımlı öğrenme ilk seferde rasgele belirlenen ağırlıklara dayanır. Ancak bu ilk rasgele seçim ağırlıklı eğitimi ile ilişkili olup son derece önemlidir. Öğretilecek vektör girişe uygulanır, doğrusal olmayan sigmoid fonksiyonu ile değerler girişten gizli katmana, oradan da çıkışa yayılır, istenilen çıktı ile gerçek olan karşılaştırılarak hata hesaplanır, hata belirli bir eşik seviyesini aştığında çıkıştan gizli katmana oradan da girişe yayılır ve ağırlıklar hata değerine göre yeniden ayarlanır (Nabiyev, 2016:598-601).

Herhangi bir tahmin problemi için tahminin performansını ölçen birçok gösterge vardır. Bu çalışmada hataların mutlak farkını yüzde olarak gösteren MAPE değeri performans ölçümü için kullanılmıştır.  $x_t$  gerçek değerler ve  $\hat{x}_t$  modeldeki tahmin değerler olmak üzere MAPE’nin formülü Eşitlik (3)’de verilmiştir (Weatherford , Gentry, & Wilamowski, 2002)

$$MAPE = \frac{\sum_{t=1}^n \left| \frac{x_t - \hat{x}_t}{x_t} \right|}{n} \times 100 \quad (3)$$

#### 4. BULGULAR

Çalışmada kullanılan 2511 işgününe ait olan veri seti, Türkiye Cumhuriyet Merkez Bankası’nın Elektronik Veri Dağıtım Sistemi (EVDS)’den alınmıştır. Bağımlı değişken BIST-100 Endeks değeri, bağımsız değişkenler, gecelik faiz oranı ve Dolar Kurudur. Veri setinin % 90’ı eğitim için (2260 veri) % 10’u (251 veri) modelin performansının testi için ayrılmıştır. Çalışmada MATLAB 2020a programı kullanılmıştır. Ağ için eğitim fonksiyonları LM, OSS, GDA arasında; aktivasyon fonksiyonları GDM, GD arasında transfer fonksiyonları da Tansig, Purelin, Logsig arasında değiştirilerek 18 deney yapılmış, deney sonuçları Tablo 1’de gösterilmiştir.

**Tablo1.** Farklı Eğitim, Aktivasyon ve Transfer Fonksiyonlarının Uygulanmasına İlişkin Sonuçlar

	Eğitim Fonksiyonu	Aktivasyon Fonksiyonu	Transfer Fonksiyonu	R			
				Eğitim	Test	Doğrulama	Toplam
1	LM	GDM	TANSIG	0,97	0,97	0,96	0,97
2	LM	GDM	PURELIN	0,94	0,93	0,94	0,94
3	LM	GDM	LOGSIG	0,76	0,79	0,74	0,76
4	LM	GD	TANSIG	---	---	---	---
5	LM	GD	PURELIN	0,94	0,94	0,93	0,94
6	LM	GD	LOGSIG	0,96	0,96	0,97	0,97
7	OSS	GDM	TANSIG	0,57	0,57	0,60	0,57
8	OSS	GDM	PURELIN	0,94	0,94	0,94	0,94
9	OSS	GDM	LOGSIG	0,73	0,70	0,73	0,73
10	OSS	GD	TANSIG	---	---	---	---



11	OSS	GD	PURELIN	0,94	0,94	0,93	0,94
12	OSS	GD	LOGSİG	0,95	0,95	0,95	0,95
13	GDA	GDM	TANSIG	0,71	0,73	0,75	0,72
14	GDA	GDM	PURELIN	---	---	---	---
15	GDA	GDM	LOGSİG	0,91	0,91	0,93	0,92
16	GDA	GD	TANSIG	---	---	---	---
17	GDA	GD	PURELIN	0,93	0,94	0,94	0,94
18	GDA	GD	LOGSİG	...	---	---	---

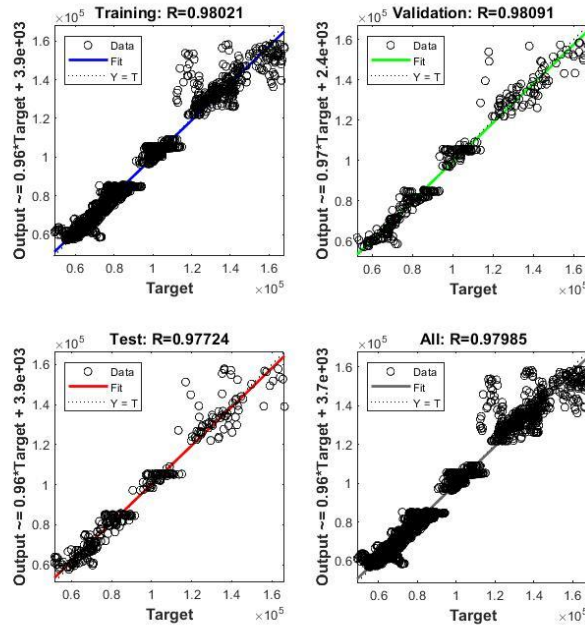
Tablo 1’de verilen R değerleri anlamsız çıktığında sonuçlar gösterilmemiştir. Tablodaki değerlere göre veri seti için eğitim fonksiyonu, öğrenme fonksiyonu ve transfer fonksiyonu olarak en iyi sonuçları veren LM (Levenberg-Marquardt), GDM ve Tansig fonksiyonu belirlenmiştir. Bundan sonraki aşamada YSA'nın farklı tipteki mimari yapıları bu fonksiyonlarla denenerek en iyi modelin kurulması amaçlanmıştır. Bu amaçla kurulan farklı modellerin mimarileri ve bu modellerin Yapay Sinir Ağları ile eğitilmeleri ile elde edilen sonuçlar Tablo 2’de verilmiştir.

**Tablo2.** Farklı Mimarideki Ağlara İlişkin Sonuçlar

	Yapı	R			
		Eğitim	Test	Doğrulama	Toplam
Model 1	2-5-1	0,97	0,97	0,96	0,97
Model 2	2-10-1	0,97	0,97	0,96	0,96
Model 3	2-20-1	-	-	-	-
Model 4	2-5-5-1	0,97	0,97	0,98	0,97
Model 5	2-5-10-1	-	-	-	-
Model 6	2-10-10-1	0,98	0,98	0,97	0,97
Model 7	2-10-20-1	-	-	-	-
Model 8	2-20-20-1	0,98	0,98	0,97	0,98

Tablo 2’de anlamsız çıkan sonuçlar gösterilmemiştir. MATLAB programında gerçek değerler ile modelden elde edilen tahmin değerler arasındaki ilişkiyi regresyon ile belirleyen modeller gösterilmektedir. Örnek olarak 6. Modele ilişkin eğitim, doğrulama, test ve toplamdaki R değerleri, Şekil 1’de verilmiştir. Şekil 1 incelenirse tahmin değerlerinin 4 durum için de regresyon doğrusunun çevresinde dizildiği, R değerlerinin de 0,97- 0,98 olduğu görülebilir. Bu durum kurulan modelin tahmin performansının iyi bir düzeyde olduğunu göstermektedir.

## Şekil 2. Model 6 için Gerçek Değerler ile Tahmin Değerler Arasındaki İlişkiler




Bundan sonraki aşamada uygun sonuçlar veren Model 1, 2, 4, 6 ve 8'in test verileri üzerinde simülasyonu gerçekleştirilmiştir. En iyi performansı gösteren modelin bulunması için Eşitlik (3)'de formülü verilen MAPE değerleri karşılaştırılmıştır. Sonuçlar Tablo 3'te verilmiştir.

**Tablo 3. En İyi Ağların Performans Sonuçları**

Ağ Yapısı	Model 1	Model 2	Model 4	Model 6	Model 8
MAPE	% 9,64	% 11,38	% 9,51	% 7,91	% 17,84

Tablo 3'e göre tahmin performansı en yüksek olan model, Model 6'dır. Model 6, mimarisi 2-10-10-1 olan iki gizli katmanlı, her gizli katmanında 10 nöron olan ağıdır, bu ağın mimarisi Şekil 2'de verilmiştir. Sonuç olarak söz konusu tarih aralığındaki BIST-100 Endeksi, gecelik faiz oranları ve Dolar Kuru arasındaki ilişkileri modelleyen ağ, eğitim fonksiyonu LM, aktivasyon fonksiyonu GDM, transfer fonksiyonu tansig olan 2-10-10-1 mimarisine sahip olan Yapay Sinir Ağı'dır.

**Şekil 3. En Uygun Ağın Mimarisi**



## 5. SONUÇLAR

Borsa verileri genellikle doğrusal olmayan veri setleri olduğundan varsayım gerektiren tahmin yöntemleri kullanılarak analiz edilmesi zordur. YSA analizi yapabilmek için bir önkoşulun sağlanması ya da bir varsayım gerekmemektedir. Bu çalışmada BIST-100 Endeks değerini tahmin etmek için Dolar Kuru ve gecelik faiz oranı bağımsız değişkenler olarak ele alınmış, değişkenler arasındaki ilişkiler YSA ile modellenmiştir. Öncelikle 2511 işgünü için EVDS' den alınan veri seti için en uygun transfer, aktivasyon ve öğrenme fonksiyonları 18 deney yapılarak belirlenmiştir. Bunun sonucunda eğitim fonksiyonu LM, aktivasyon fonksiyonu GDM transfer fonksiyonu tansig olarak belirlenmiştir. İkinci aşamada veri seti içindeki ilişkileri modelleyen en uygun ağı tespiti için çeşitli mimarilerdeki modeller kurularak model performansları MAPE değerleri ile karşılaştırılmıştır. Bu modellerden performansı en iyi olan ağ, mimarisi 2-10-10-1 olarak belirlenmiştir.

Araştırma, literatürdeki birçok çalışma ile benzer olarak YSA'nın finans alanındaki çalışmalarda iyi bir tahmin modeli kurma yöntemi olduğunu göstermiştir. İki bağımsız değişken ile bağımlı değişkeni iyi bir performansla tahmin eden en iyi model kurulmuştur. Çalışmada tahmin performansı göstergesi olarak kullanılan MAPE değeri, Model 6 için % 7,91'dir. Yani çalışmada kurulan modelle tahmin edilmiş olan veriler, gerçek verilerden % 7,91 oranında sapma göstermektedir. Lewis (1982) MAPE değerinin % 10'un altında olan modellerin tahmin performansını "çok iyi" olarak değerlendirmektedir.

Araştırma sonuçlarının Borsa alanında çalışan araştırmacı ve uygulayıcılar açısından örnek teşkil edebilir, iktisadi karar birimleri için ve hisse senedi piyasasındaki yatırımcılar için yol gösterici olabilir.

## KAYNAKÇA

- Akcan, A. ve Kartal, C. (2011). İMKB Sigorta Endeksini Oluşturan Şirketlerin Hisse Senedi Fiyatlarının Yapay Sinir Ağları ile Tahmini. Muhasebe ve Finansman Dergisi. Temmuz. (27-40).
- Çalışkan, M.M.T, Deniz, D. (2015). Yapay Sinir Ağlarıyla Hisse Senedi Fiyatları ve Yönlerinin Tahmini. Eskişehir Osmangazi Üniversitesi İİBF Dergisi, Aralık,10 (3), (177-194).
- Dorofki, M., Elshafie, A.H., Jaafar, O., Karim, O.A. Mastura, S. (2012). Comparison of Artificial Neural Network Transfer Functions Abilities to Simulate Extreme Runoff Data. International Conference on Environment, Energy and Biotechnology IPCBEE vol.33 Press, Singapore.
- EVDS (2019). Türkiye Cumhuriyet Merkez Bankası Elektronik Veri Dağıtım Sistemi. [https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket/collapse\\_1/5854/DataGroup/turkish/bie\\_mkbrgn/](https://evds2.tcmb.gov.tr/index.php?/evds/serieMarket/collapse_1/5854/DataGroup/turkish/bie_mkbrgn/) Adresinden 08.01.2020 tarihinde alınmıştır.

- Ghiassi, M., & Saindane, H. (2005). A Dynamic Architecture for Artificial Neural Networks. *Neurocomputing*, 63, (397–413).
- Güresen, E., Kayakutlu, G. ve Daim, T.U. (2011). Using Artificial Neural Network Models in Stock Market Index Prediction. *Expert Systems with Applications*. 38. (10389-10397).
- Haykin, S. (2009). *Neural Networks and Learning Machines*. Third Edition. Boston: Pearson International Edition.
- Kattan, A., Abdullah, R., & Geem, Z. W. (2011). *Artificial Neural Network Training and Software Implementation*. Newyork: Nova Science.
- Kutlu, B. ve Badur, B. (2009). Yapay Sinir Ağları ile Borsa Endeksi Tahmini. *Yönetim*. Yıl: 20, Sayı: 63.(25-40).
- Laurakis, M.I.A. (2005). A Brief Description of Levenberg - Marquard Algorithm implemented by Levmar. *Foundation of Research and Technology*, (1-6).
- Lewis, C. D. (1982). *Industrial and Business Forecasting Methods*. London: Butterworths.
- Merh, N., Saxena, V.P. ve Pardasani, K.R. (2011). Next Day Stock Market Forecasting: An Application of ANN and ARIMA. *The IUP Journal of Applied Finance*, Vol. 17, No. 1. (70-84).
- Moghaddam, A.H., Moghaddam, M.H., Esfandyari, M. (2016). Stock Market Index Prediction Using Artificial Neural Network. *Journal of Economics, Finance and Administrative Sciences*. 21. (89-93).
- Mukkamala, S., Sung, A.H. ve Abraham, A. (2003). Intrusion Detection Using Ensemble of Soft Computing Paradigms. (Ed: A. Abraham, K. Franke ve M. Köppen). *Intelligent System Design and Application İçinde*. (239-250). New York: Springer.
- Nabiyev, V. (2016). *Yapay Zekâ. Stratejili Oyunlar, Örüntü Tanıma, Doğal Dil İşleme*. Genişletilmiş 5. Baskı. Ankara: Seçkin Yayıncılık.
- Roh, T. H. (2007). Forecasting the Volatility of Stock Price Index. *Expert Systems with Applications*, 33, (916–922).
- Shanmuganathan, S. (2016). *Artificial Neural Network Modelling: An introduction*. (Ed: Shanmuganathan, S & Samarasinghe, S.) *Artificial Neural Network Modelling İçinde*. (1-14), Switzerland: Springer.
- Sibi,P., Jones, S.A & Siddarth, P. (2013). Analysis of Different Activation Functions Using Back Propagation Neural Networks. *Journal of Theoretical and Applied Information Technology*. Vol. 47 No.3.(1264-1268).

- Tektaş, A. ve Karataş, A. (2004). Yapay Sinir Ağları ve Finans Alanına Uygulanması: Hisse Senedi Fiyat Tahminlemesi. *İktisadi ve İdari Bilimler Dergisi*, Cilt: 18 Sayı: 3-4.(337-349).
- Uşul, H., Küçükşille, E. ve Karaoğlan, S. (2017). Güven Endekslerindeki Değişimlerin Hisse Senedi Piyasalarına Etkileri: Borsa İstanbul Örneği. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, C.22, S.3, (685-695).
- Weatherford, L.R., Gentry, T.W. & Wilamowski, B. (2002). Neural Network Forecasting for Airlines: A Comparative Analysis. *Journal of Revenue Pricing Management*, 1(4), (319-331).
- Yakut, E., Elmas, B. ve Yavuz, S. (2014). Yapay Sinir Ağları ve Destek Vektör Makineleri Yöntemleriyle Borsa Endeksi Tahmini. *Süleyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*. C.19. S.1.(139-157).