



Journal of Economics and Financial Researches, 2021, 3(1): 1-8

Borsa Endekslerinin Birbirleriyle Etkileşimi ve Endeks Yönünün Tahmini: BİST100 Üzerine Bir Uygulama^a

Ali Can Demirel^b & Adalet Hazar^c

Öz

Küreselleşmenin etkisi her alanda olduğu gibi sermaye piyasalarında da kendini göstermektedir. Hisse senedi fiyatları, tahvil fiyatları, endeks hareketleri gibi göstergeler, iç pazardaki faktörlere bakılarak tahmin edileceği gibi dış pazarda meydana gelen değişimlerden de etkilenmektedir. Yatırımcılar, katlanabilecekleri riskleri öngörmeleri halinde alım-satım işlemlerini bu yönde arttırıp, azaltabilirler. Yatırımcılar için öngörülmek istenen bilgilerden biri de borsa endeks hareketleridir. Bu çalışmada, etkin ve büyüklük sıralamalarında önde gelen DOW 30, DAX, FTSE 100 ve EURO STOXX 50 endekslerinin 2014-2019 yılları günlük hareketleri alınarak, BIST 100 endeksi hareket yönleri tahmin edilmeye çalışılmıştır. Girdi değişken olarak kullanılan endeks hareketlerinin yönleri artış ve azalış olarak sınıflandırılmıştır. Son yıllarda özellikle sınıflandırma problemlerinde başarısı yüksek olan ve öğrenmeye dayalı kullanılan yöntemlerden biri olan yapay sinir ağları, yöntem olarak kullanılmıştır. Çalışma sonucunda BIST 100 endeksi değişim yönleri %59,57 başarı oranıyla doğru tahmin edilmiştir.

Anahtar

Kelimeler:

Yapay Sinir Ağları,
BIST 100 Endeks
Hareketleri
Tahmini, Derin
Öğrenme

JEL

Sınıflandırması:

C51, C52, C53

Interaction of Stock Market Indices With Each Other and The Prediction of Index Direction: An Application on BIST100

Abstract

As well as in every area, globalization shows its effect in capital markets. Indicators such as stock prices, bond prices, and index movements can also be estimated based on the factors in the domestic market, like the changes in the foreign market. Investors can either increase or decrease their trading in this direction if they anticipate the risks that they can bear. One of the information, that investors want to foresee, is stock market index movements. In this study, the daily movements of the DOW 30, DAX, FTSE 100, and EURO STOXX 50 indices, which are leading in the effective and size rankings, were used to estimate the movement directions of the BIST 100 index. The direction of index movements used as input variables, are categorized into two groups as increase and decrease. The artificial neural network method, one of the methods with high success especially in classification problems in recent years, has been used. The application was made with the method based on machine learning. As a result, the final as high as success rate is 59.57 %.

Keywords:

Artificial Neural
Networks,
BIST 100 Index
Movements
Estimation, Deep
Learning

JEL Classification:

C51, C52, C53

^a Bu çalışma 22-24.10.2020 tarihlerinde yapılan 1. Ulusal Uygulamalı Sosyal Bilimler Kongresi'nde (C-IASOS-Ulusal 2020) sunulan tebliğin gözden geçirilmiş ve düzeltilmiş halidir.

^b Doktora Öğrencisi, Başkent Üniversitesi Sosyal Bilimler Enstitüsü Uluslararası Finans ve Bankacılık Bölümü, alcnemirel@gmail.com, ORCID: 0000-0002-7021-6136

^c Prof. Dr., Başkent Üniversitesi, Ticari Bilimler Fakültesi Uluslararası Finans ve Bankacılık Bölümü, ahazar@baskent.edu.tr, ORCID: 0000-0002-1483-8360

1. Giriř

Sermaye piyasalarında iřlem gren finansal rnlerin, alternatif yatırımların eřitlendirilmesi ve yksek getiri kazandırma olanakları, geliřmekte olan lkelere ynelik sermaye akımlarını artırabilmektedir. Sermaye akımları, geliřmekte olan lke ekonomilerine, ekonomik sistemlerin dıřa aılması ve yurt dıřı piyasalarla rekabet gibi nemli avantajlar kazandırmaktadır. Yatırımcıların avantajı ise finansal varlık deęerleme modelinin (CAPM) temeli olan getiri ile risk arasındaki iliřkiyi dikkate alarak yksek kazanç elde etmesidir. Yatırımcılar, risk faktrnn takibi aısından birok veriyle ilgilenmektedirler. Yurt iinde ve yurt dıřında finansal piyasaların birbiriyle etkileřimi, yatırımcıların alım-satım iřlemlerinde i ve dıř piyasada oluřabilecek vaka takiplerini birlikte izlemeye yneltmektedir. Sermaye piyasası aralarının fiyatları bu nedenlerle deęiřim gstermektedir. Yatırımcıların, risk unsurları aısından ilgilendikleri gstergelerden biri borsa endeks hareketleridir. Hisse senetlerinin belirli aęırlıklarla hesaplanması sonucuyla oluřan bu deęerler, piyasada bulunan yatırımcıların iřlemlerinde alım-satım zetini taraflara gstermektedir. BIST 100 endeksi, yatırımcılar aısından gsterge olarak kabul edilmektedir. Bu sebeple yatırımcılar tarafından borsanın dřme ve ykselme ynleri BIST 100 endeksinde dikkate alınır. Yatırımcılar, yatırım aralarının performansını izleyebilmek, borsanın ynn grebilmek ve alım-satım kararlarını alabilmek iin eřitli tahmin yntemlerine ihtiya duyarlar. Risk faktrlerinin direkt olarak tahmini mmkn olmasa bile, oęu yatırımcı alım-satım iřlemlerinden nce arařtırma yapmaktadır. Arařtırma ve tahmin sonuları karar vericileri etkilemektedir. Borsa endeks hareketleri iin bařarılı tahminlerin retilmesiyle, piyasa stratejilerinin geliřtirilmesi ve yatırımcıların piyasa riskleri ve spekulatrlere karřı korunma fırsatına sahip olmaları saęlanır (Leung vd., 2000: 178). Bu alıřmada, etkin ve byklk sıralamalarında nde gelen DOW 30, DAX, FTSE 100 ve EURO STOXX 50 endekslerinin 2014-2019 yılları gnlk hareket ynleri alınarak, BIST 100 endeks hareket ynleri tahmin edilmeye alıřılmıřtır. alıřmada kullanılan yapay sinir aęları yntemi ile 4 farklı model oluřturulmuřtur. Yntemin aralarından olan nron ve katman sayılarının arttırılması, literatrdeki alıřmalardan farklı olarak modelin bařarı oranında olumsuz etkiye neden olmuřtur.

2. Literatr

alıřmasında %90 bařarı oranı elde etmiř olan Schoeneburg (1990) hisse senetlerinin gnlk fiyatlarını kullanarak, bir sonraki gnn deęerlerini ngrmeye alıřmıřtır. Modelinde geriye yayılım algoritmaları uygulamıřtır. NASDAQ, DJIA ve S&P500 gibi endekslerin 30 gnlk fiyatlarını eęiten Malakooti ve AghaSharif (2015), arařtırma sonularında %76 oranında bařarı elde etmiřlerdir. Destek vektr makineleri ve genetik algoritmalar kullanılmasının optimizasyon ařamasında bařarı skorunu arttırdıęı savunulmuřtur.

Kutlu ve Badur (2009) alıřmasında dolar ve gecelik faiz gibi deęiřkenleri kullanarak, borsa endeks deęerlerini tahmin etmeyi amalamıřtır. %96 oranında bařarı

gösteren çalışmada ileri beslemeli yapay sinir ağları kullanılarak günlük veriler kullanılmıştır. BIST 100 endeksinin hareket yönlerini öngörebilmek için yapay sinir ağı ve destek vektör makineleri kullanan Pabuçcu (2019) günlük kapanış fiyatlarını kullanmıştır. Sınıflandırma problemlerinde destek vektör makineleri yönteminin daha iyi sonuç ortaya koyduğu gözlemlenmiştir.

Gündüz vd. (2017), BIST endeksinde işlem gören hisse senetleri fiyatlarının günlük değişimlerini, yapay sinir ağları yöntemi uygulayarak başarı oranlarını karşılaştırmıştır. En yüksek hissenin başarı oranı %61 olarak ortaya konmuştur. Çalışmalarında NASDAQ günlük borsa endeksinin günlük kapanış fiyatlarını eğitime sokan Moghaddam vd. (2016) ileri gün fiyatlarını başarılı şekilde tahmin etmişlerdir. Özer vd. (2017), çeşitli ülkelerin endeks hareketlerini eğiterek, bulanık mantık yöntemleri ve geleneksel tahmin yöntemlerini kullanmıştır. Başarı oranları kıyaslamasında bulanık mantık yöntemlerinin daha yüksek başarı sonucu verdiği ortaya konulmuştur. BIST içinde işlem gören hisse senetlerinin kapanış fiyatlarını girdi değişken belirleyerek çalışmalarında kullanan Yiğiter vd. (2017), regresyon ve yapay sinir ağı yöntemlerini kullanarak, makine öğrenmesi metotlarının alternatif yöntem olarak kullanılabilceğini ve başarılı sonuç verebileceğini göstermiştir. Özçalıcı (2016), Borsa İstanbul 30 endeksinde listelenen şirketlerin hisse senetlerinin fiyat ve hacim bilgilerini girdi değişken olarak kullanmıştır. Hisse senetlerinin fiyat hareketlerini 20 gün önceden yaklaşık %73 başarıyla doğru tahmin etmiştir. Vui vd. (2014), Borsa endeksinde belirsizlik hâli ve fiyat tahminlerini bilgisayar bilimi yöntemleri kullanarak uygulamıştır. Yatırım için karar verme konusunda çeşitli yöntemlerden, yapay sinir ağları tekniklerinin kullanımını önermiştir. Zhang ve Wu (2009), S&P endeksinin günlük belirlenen hareketlerinin tahmini için yapay sinir ağları metodu ile IBCO (improved bacterial chemotaxis optimization) ve BP (back-propagation) tekniklerini kullanmıştır. Kullanılan teknikler tahmin yönteminin başarısında ileri beslemeli tekniğin doğruluk oranını arttırdığı sonucu bulunmuştur. Liu ve Wang (2012), Şangay borsasının endeks kapanış göstergelerini tahmin etmek amacıyla 3 katmanlı ileri beslemesi yapay sinir ağı mimarisi oluşturmuştur. Farklı örneklemeler alınarak tahminlerin duyarlılığı ölçülmüştür. Selvamuthu ve diğerleri (2019) Hindistan firmalarının, hisse senedi getiri tahminlerini, 3 farklı algoritma kullanarak, %96 üzerinde doğruluk oranı sonucuyla ortaya koymuşlardır.

3. Veri ve Yöntem

Çalışmada kullanılan 2014-2019 yılları arası, *DOW 30*, *DAX*, *FTSE 100*, *EURO STOXX 50* ve *BIST 100* endekslerinin günlük hareketleri investing.com'un veri tabanından alınmıştır. Belirtilen endekslerin seçilmesi, ortak çalışma günlerinin ve ortak tatil günlerinin olması sebebiyle veri sayısının korunmasına yöneliktir. Asya borsalarının, çalışmaya dahil edilmesi veri sayısının düşmesine ve gün çakışmalarının artmasına neden olacağı için çalışmaya dahil edilememiştir. Maksimum veriyi sağlayacak şekilde seçilen endekslerde, çakışan günler test veri kümesinden arındırılmıştır. Elde edilen verilerde açılış, en yüksek değer, en düşük değer ve günlük değişim verisi bulunmaktadır. Bu veri tabanından günlük değişim değeri kullanılmıştır. Problemi basitleştirmek için ikili sınıflandırma yöntemi gerçekleştirilmiştir. Bu sebeple endekslerin günlük hareket yönleri

artmıř ise 1 olarak, azalmıř ise 0 olarak etiketlenilmiřtir. Sınıflandırma probleminde, gözlemler kümesi ve bir hedef sınıfı, bilinmeyen veri kümesinin kayıtları yardımıyla temsil edilir (Kuzey, 2012: 13). Deęiřimin olmadıęı veriler temizlenmiřtir. Son durumdaki veri kümesinde toplamda 5275 adet örnek oluřturulmuřtur. Oluřturulan veri kümesi yapay sinir aęlarının eęitilmesinde kullanılmıřtır.

Tablo 1. Girdi ve Çıktı Deęiřkenlerinin Sınıflandırılması

Girdi		Çıktı	
DOW 30	DAX	EUTO STOXX 50	BIST 100
1	1	0	1
0	0	0	0

Etik kurul izni ve/veya yasal/özel izin alınmasına gerek olmayan bu çalıřmada arařtırma ve yayın etięine uyulmuřtur.

3.1. Yapay Sinir Aęları

Yapay sinir aęları, yeni bilgileri üretme ve öngörebilme gibi yetenekleri herhangi bir dayanaktan yardım almadan gerçekleřtirebilen makine öęrenmesi sistemleridir (Öztemel, 2006: 16-21). Bu yeteneklerin gerçekleřmesi, öęrenme sürecinin modellenmesiyle iliřkilidir. Bilgi modele kaydedildikten sonra, hedef belirlenir ve nöronlar içerisindeki aęlırlıklar güncellenir. Girdiler, nöronlar içerisinde aęlırlık katsayılarıyla çarpılarak çekirdeęe doęru yönlendirilir. Aęlırlık katsayılarının deęeri etkisiz olabileceęi gibi negatif ve pozitif deęerler de olabilir.

Yapay sinir aęı mimarisi katmanlardan oluřmaktadır. Nöronlara aktarılan bilgiler bir bařka nörondan gelebileceęi gibi uzaydan da direkt olarak gelebilir. Dıřarıdan direkt olarak gelen girdiler giriř katmanını oluřturmaktadır. Dolayısıyla girdiler bu katmanda aęlırlıklarla bir iřleme maruz kalmazlar ve bir sonraki katmana iletilirler. Gizli katman, verilerin ve karmařık problemlerin çözülmesinde katkı saęlamaktadır. Yapay sinir aęı mimarisinde bulunan gizli katman ve nöron sayıları farklı olabilir. Problemin gücüne göre en iyi sonucu almak için bu unsurların sayılarında artış veya azalıř söz konusu olabilmektedir. Sonuç katmanı, dięer katmanlardan iřlenerek gelen verilerin çıktılarına oluřturan alandır. Çıktılar buradan uzaya aktarılmaktadır.

Yapay sinir aęlarında, öęrenme süreci, örneklerden ve geçmiř tecrübelerden yararlanılarak geliřtirilebilir. Bilgi, yapay sinir aęı mimarisinin içerisinde bulunan baęlantıların aęlırlık deęerlerinde olup, bu bilgi tüm baęlantılara nüfuz etmiř durumdadır (Öztemel, 2006: 16-21). Eęitim veri kümesi, tasarlanan yapay sinir aęına girdi olarak verilir. İleri besleme ařamasında ilgili aęlırlıklar (w_i) ile veriler (x_i) çarpılır, bias parametresiyle (b) toplanır, aktivasyon fonksiyonu uygulanır ve son olarak sinir aęının sonunda çıktı elde edilir (y). Verilerin gerçek etiketleri ile yapay sinir aęının çıktısı karřılařtırılarak hata deęeri belirlenir. Ortaya çıkan hata deęerine göre ilgili aęlırlıklar güncellenir (w_i). Bu iřlem, hata oranı istenen deęere ulařıncaya kadar devam eder. En uygun hata deęeri bulununca eęitim tamamlanır ve test için ayrılan veri kümesi üzerinde test edilir. Bu çalıřmada, BIST 100 hareket yönünü tahmin etmek için 4 farklı yapay sinir

ağı mimarisi tasarlanmıştır. Her modelin 4 girdisi ve 1 çıktısı vardır. Gizli katman sayısı ve gizli katmanın bulundurduğu nöron sayıları değiştirilerek farklı sinir ağı mimarileri elde edilmiştir. İlk olarak, sinir ağına tek gizli katman tasarlanmış ve gizli katmandaki nöron sayısı 10 ve 50 olacak şekilde farklı sinir ağları eğitilmiştir. İkinci aşamada ise sinir ağı mimarisinin gizli katman sayısı artırılarak, performansları karmaşıklık (Tablo 1) matrisi ile gözlemlenmiştir. Tasarlanan yapay sinir ağı mimarilerinin performansını gözlemlemek için çapraz doğrulama tekniği kullanılmıştır.

$$y = \sum_{i=1}^n w_i x_i + b \quad (1)$$

Yapay sinir hücresinin çıktısı, aktivasyon fonksiyonu kullanılarak hesaplanan çıktı değeridir. Üretilen çıktı, dış dünyaya veya diğer bir hücreye gönderilir. Bunun yanında hücre kendi çıktısını kendisine girdi olarak da gönderebilir. Problemlerin çözümünde genellikle aktivasyon fonksiyonu olarak Sigmoid fonksiyonu kullanılmaktadır. Türevi alınabilir, sürekli ve doğrusal olmayan bir fonksiyon olmasından dolayı doğrusal olmayan problemlerin çözümünde yaygın olarak kullanılır. Fonksiyonu matematiksel tanımı aşağıdadır.

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

Hata fonksiyonlarında ise ortalama hataların karesi metodu kullanılmıştır (MSE).

$$MSE = \frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2 \quad (3)$$

Ağın içerisinde bulunan ağırlık değerlerinin kullanılması, eğitim veya öğrenme olarak tanımlanır. Diğer bir ifadeyle, girdilerin ağırlık değerlerine ulaşması işlemi, ağın öğrenme süreci olarak adlandırılmaktadır. İleri besleme aşamasında ilgili ağırlıklar ile veriler çarpılır ve aktivasyon fonksiyonu uygulanır. Son olarak sinir ağının sonunda çıktı elde edilir (y). Verilerin gerçek etiketleriyle yapay sinir ağının çıktısı karşılaştırılarak hata değeri belirlenir. Ortaya çıkan hata değerine göre ilgili ağırlıklar saptanmaktadır (w_i). Bu işlem hata oranı istenen değere ulaşmaya kadar devam eder. En uygun hata değeri bulununca eğitim tamamlanır ve test için ayrılan veri kümesi üzerinde test edilir. Bu çalışmada, BIST 100 hareket yönünü tahmin etmek için 2014-2018 yılları arasında alınan günlük değişimler sinir ağının öğrenme sürecinde kullanılmıştır.

4. Bulgular

Tahminlerin doğruluğu hakkında bilgi vermek için karmaşıklık matrisi, ölçüm aracı olarak kullanılmıştır. Ölçümün doğruluğunun kavranması, kolay bilgiler sağlanması ve özellikle sınıflandırma algoritmalarında sıklıkla kullanılan bir tablo olması ölçümün değerlerinin anlaşılmasını kolaylaştırmıştır. Matriste bulunan gerçek pozitifler, gerçek değeri 1 ve tahmin ettiğimiz değer de 1 olduğu örneklerdir. Gerçek negatifler, gerçek değeri 0 ve tahmin ettiğimiz değer de 0 olduğu örneklerdir. Yanlış pozitifler, gerçek değeri 0 ancak tahmin ettiğimiz değer de 1 olduğu örneklerdir. Yanlış negatifler ise gerçek değeri 1 ancak tahmin ettiğimiz değer de 0 olduğu örneklerdir. Model 1'de doğru pozitif oranı 439, yanlış pozitif oranı 262, yanlış negatif değeri 143 ve doğru negatif değeri 156

performans göstermiştir. Model 2’de doğru pozitif oranı 421, yanlış pozitif oranı 252, yanlış negatif değeri 162 ve doğru negatif değeri 169 performans göstermiştir. Model 3’de doğru pozitif oranı 398, yanlış pozitif oranı 423, yanlış negatif değeri 154 ve doğru negatif değeri 122 performans göstermiştir. Model 4’te ise doğru pozitif oranı 411, yanlış pozitif oranı 254, yanlış negatif değeri 130 ve doğru negatif değeri 124 performans göstermiştir.

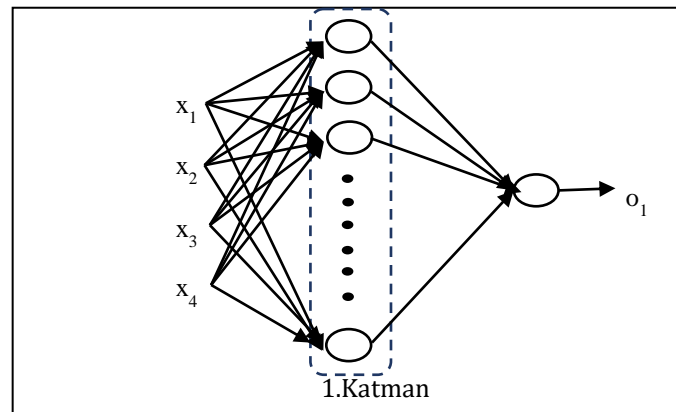
Tablo 2. Karmařıklık Matrisi

Tahmin Edilen	Gerçek	
	Pozitif	Negatif
	Pozitif	Doğru Pozitif
Negatif	Yanlış Negatif	Doğru Negatif

Tablo 3. Yapay Sinir Ağları Kullanılarak Oluřturulan Modeller

Model No	Gizli Katmanlar (Nöron Sayıları)				Performans (%)
	1	2	3	4	
1	10	-	-	-	59,57
2	50	-	-	-	59,37
3	10	5	-	-	59,47
4	10	5	5	4	51,47

Yapay sinir ağı yöntemi kullanılarak oluşturulan 4 modelin eğitimden sonraki bilgileri tahmin etme başarısı, her bir modelde %50 oranının üzerinde çıkmıştır (Tablo 3). Çalışmada ilk olarak kullanılan model 1’de tek katmanlı yapay sinir ağı mimarisi eğitilmiştir. Bu modelde 10 adet nöron kullanılmıştır. Model 2’de yine tek katman kullanılmıştır fakat 10 olan nöron sayısı 50’ye çıkarılmıştır. Eğitimden sonraki başarısı %59,37 olarak gerçekleşmiştir. Böylece tek katmanlı yapıda, nöron sayısının artması model performansını düşürdüğü gözlemlenmiştir. Başarı skorunu yükseltmek için daha sonra mimaride gizli katman sayısı artırılmıştır. Model 3’te 10 ve 5 nöronlu çift katmanlı mimari oluşturulmuştur. Performansı 59,47 başarı oranında gerçekleşmiştir. Katman sayısını artırarak model 2’ye göre performansın yükseldiği görülerek, son olarak model 4’te 4 katmanlı 10,5,5,4 nöronlu mimari oluşturulmuştur. Başarı skoru model 3 ile eş çıkmıştır.



Şekil 1. Maksimum Performans Gösteren Yapay Sinir Ağ Mimarisi (Model 1)

5. Sonuç ve Tartışma

Günümüzde yatırımcılar, alım satım işlemlerine birçok faktöre bakarak karar verirler. BIST 100, işlem gören piyasa ve işlem hacmi açısından en yüksek pay senetlerinin performansını gözlemlemek için kullanılan önemli endekslerden olup, sermaye piyasalarının yatırımcılar nezdinde referansı kabul edilir. Yatırımcılar tarafından borsanın düşme ve yükselme yönleri BIST 100 endeksinde dikkate alınır. Bu endekste gerçekleşecek hareketler, korunma veya spekülasyon amaçlı sinyalleri gösterebilir. Yüksek getiri sağlamak isteyen yatırımcılar belirsizliğin yüksek olduğu piyasalarda işlem yapmak isteyebilirler. Risk faktörü iç ve dış etkenlerden belli ölçüde etkilenebilmektedir. Bu etkenlerden biri de yabancı borsa endeks hareketleridir. Globalleşen piyasalarda bir ülkenin ekonomik unsurları diğer bir ülkeyi etkilemektedir. Borsa endeks hareketlerinin tahmini, yatırımcıların varlık alım-satımında karar verici etkenlerden biridir. Bu çalışmada sınıflandırma problemlerinde başarılı olan yapay sinir ağları yöntemi kullanılarak, 2014-2019 yılları arasındaki günlük hareketlerin artış azalış yönlerinden faydalanılmıştır. Etkinlik ve büyüklük sıralamalarında önde gelen DOW 30, DAX, FTSE 100 ve EURO STOXX 50 endekslerinin hareket yönleri günlük olarak tahmin edilmiştir. Nöron ve katman sayıları değiştirilerek toplam 4 model ortaya konulmuştur. Çalışma sonucunda en iyi modelden %59,57 başarı skoru elde edilmiştir. İleri beslemeli modellerde nöron ve katman sayılarının artırılması, başarı performansını olumsuz yönde etkilemiştir. Selvamuthu ve diğerleri (2019) oluşturdukları modelde derinleşmeye giderek doğruluk oranını yükseltmiştir. Oluşturduğumuz 4 modelde ise katman sayısı artınca doğruluk oranı azalmıştır. Bu çalışmada, borsa endeks hareketleri tahmini, geleneksel tahmin yöntemlerine alternatif olarak makine öğrenmesi ve derin öğrenme yöntemlerinin kullanılabilmesi gösterilmek istenmiştir. İleride yapılacak olan çalışmalarda geleneksel yöntemler ile makine öğrenmesi tahmin metodlarının doğruluk oranları karşılaştırılarak, hangi yöntemin daha yüksek başarı oranı verdiği tartışılabilir.

Araştırmacıların Katkı Oranı Beyanı

Yazarlar makaleye eşit oranda katkı sağlamış olduklarını beyan eder.

Araştırmacıların Çıkar Çatışması Beyanı

Bu çalışmada herhangi bir potansiyel çıkar çatışması bulunmamaktadır.

Kaynakça

- Chen, A.S. and Leung, M.T. (2004). Regression neural network for error correction in foreign exchange forecasting and trading. *Computers & Operations Research*, 31(7): 1049-1068.
- Gündüz, H., Çataltepe, Z. and Yaslan, Y. (2017, May). Stock market direction prediction using deep neural networks. Paper presented at the *25th Signal Processing and Communications Applications Conference (SIU)*, Antalya. Retrieved from <https://ieeexplore.ieee.org/document/7960512>
- Kutlu, B. ve Badur, B. (2009). Yapay sinir ağıları ile borsa endeksi tahmini. *Yönetim Bilimleri Dergisi*, 20(63): 25-40.
- Kuzey, C. (2012). *Veri madenciliğinde destek vektör makineleri ve karar ağaçları yöntemlerini kullanarak bilgi çalışanlarının kurum performansı üzerine etkisinin ölçülmesi ve bir uygulama* (Yayınlanmamış Doktora Tezi). İstanbul Üniversitesi Sosyal Bilimler Enstitüsü, İstanbul.
- Leung, M.T., Daouk, H. and Chen, A.S. (2000). Forecasting stock indices: A comparison of classification and level estimation models. *International Journal of Forecasting*, 16(2): 173-190.
- Liu, F. and Wang, J. (2012). Fluctuation prediction of stock market index by legendre neural network with random time strength function. *Neurocomputing*, 83: 12-21.
- Malakooti, M.V. and AghaSharif, A. (2015, Jan). Prediction of stock market index based on neural networks, genetic algorithms and data mining Using Svd (pp. 29-40). *The Proceedings of the International Conference on Digital Information Processing Data Mining and Wireless Communications*, Dubai, UAE.
- Moghaddam, A.H., Moghaddam M.H. and Esfandyari M. (2016). Stock market index prediction using an artificial neural network. *Journal of Economics Finance and Administrative Science*, 21(41): 89-93.
- Özçalıcı, M. (2016). Yapay sinir ağıları ile çok aşamalı fiyat tahmini: BIST 30 senetleri üzerine bir araştırma. *Dokuz Eylül Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 31(2): 209-227.
- Özer, A., Sarı, S.S. ve Başakın, E.E. (2017). Bulanık mantık ve yapay sinir ağıları ile borsa endeksi tahmini: Gelişmiş ve gelişmekte olan ülkeler örneği. *Hitit Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 11(2): 99-123.
- Öztemel, E. (2006). *Yapay sinir ağıları*. Türkiye: Papatya Yayınevi.
- Pabuççu, H. (2019). Borsa endeksi hareketlerinin tahmini: Trend belirleyici veri. *Selçuk Üniversitesi Sosyal Bilimler Yüksekokulu Dergisi*, 22(1): 246-256.
- Schoeneburg, E. (1990). Stock price prediction using neural networks: A project report. *Neurocomputing*, 2(2): 17-27.
- Selvamuthu, D., Kumar, V. and Mishra, A. (2019). Indian stock market prediction using artificial neural networks on tick data. *Financial Innovation*, 6(5): 1-12.
- Vui, S.C., Soon, K.G., On, K.C., Alfred, R. and Anthony, P. (2013, Nov). *A review of stock market prediction with Artificial neural network (ANN)*. Paper presented at the 2013 IEEE International Conference on Control System, Computing and Engineering, Malaysia. Retrieved from <https://ieeexplore.ieee.org/document/6720012>
- Yiğiter, Ş.Y., Sarı, S.S. ve Başakın, E.E. (2017). Hisse senedi kapanış fiyatlarının yapay sinir ağıları ve bulanık mantık çıkarım sistemleri ile tahmin edilmesi. *Kahramanmaraş Sütçü İmam Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7(1): 1-22.
- Zhang, Y. and Wu, L. (2009). Stock market prediction of S&P 500 via combination of improved BCO approach and BP neural network. *Expert Systems with Applications*, 36(5): 8849-8854.