

## Bütünleşik Dalgacık Dönüşümü-Evrişimsel Sinir Ağları Tabanlı Derin Öğrenme Yaklaşımı ve Borsa Tahmini Üzerine Bir Uygulama

Hamit ERDAL\*

Selçuk KORUCUK\*\*

### Öz

Finansal tahminleme çalışmalarında üzerinde en fazla çalışılan konulardan biri borsa tahminidir. Risk yoğun bir yatırım aracı olan borsa için iyi bir tahmin aracının veya metodolojisinin geliştirilebilmesi yatırımcılar için paha biçilemez önemdedir. Bu çalışmada, Borsa İstanbul Sınai endeksi günlük verisi ile bir borsa tahmini çalışması gerçekleştirilmiş ve borsanın açık olduğu 5.000 günlük (31.12.2001-31.12.2021) endeks açılış fiyatları kullanılarak tahmin için 3 model kurulmuştur. Model 1.'de 1 gün geriden gelen değerlerle, Model 2.'de 3 gün geriden gelen değerlerle ve Model 3.'de ise 7 gün geriden gelen değerlerle tahmin yapılmıştır. Tahmin yöntemi olarak etkinliği pek çok çalışmada ortaya konulmuş bir derin öğrenme yöntemi olan Evrişimsel Sinir Ağları (ESA) ve Dalgacık Dönüşümü (DD) ile önışleme tabi tutulmuş ESA (DDESA) yöntemleri kullanılmıştır. Böylece durağan bir durum için veri kümesini alt kümelerle ayrıştıran dalgacık dönüşümünün tahmin performansına etkisi araştırılmıştır. Çalışmanın sonucunda DDESA yaklaşımı ile tahmin başarısının artırılabilirdiği ve etkin bir tahminleme aracı olarak kullanılabilirdiği sonucuna ulaşılmıştır.

**Anahtar Kelimeler:** Borsa, Tahminleme, Derin Öğrenme, Dalgacık Dönüşümü, Evrişimsel Sinir Ağları.

**JEL Kodları:** C13, C45, C51.

## An Integrated Wavelet Transform-Convolutional Neural Network Based Deep Learning Approach and An Application On Stock Exchange Estimation

### Abstract

Stock market estimation is one of the most studied topics in financial estimation studies. Developing a better estimation tool or methodology for the stock market, which is a risk-intensive investment tool, is invaluable for investors. In this study, a stock market estimation study was carried out with the daily data of Borsa İstanbul (BIST) Industrial index (XUSIN). In this context, the opening prices of the 5,000-day index (31.12.2001-31.12.2021) were utilized and three models were developed for estimating. In Model 1, estimations were conducted with values that 1 day behind; in Model 2, with values that 3 days behind and in Model 3, with values that 7 days behind, respectively. Convolutional Neural Network (CNN) and Wavelet Transform Convolutional Neural Network (WTCNN), which are deep learning methods whose effectiveness has been demonstrated in many studies, were utilized as estimation methods. Thus, the effect of wavelet transforms which decomposes dataset into subsets for a stationary situation for estimation performance was investigated. It was concluded that the estimation success could be increased with the DDESA approach and it could be used as an effective estimation tool.

**Keywords:** Stock Exchange, Estimation, Deep Learning, Wavelet Transform, Convolutional Neural Network.

**Geliş/Received:** 01.03.2023

**Kabul/Accepted:** 24.09. 2023

**Etik Kurul Beyanı:** Bu araştırmada, anket, mülakat, odak grup çalışması, gözlem, deney, görüşme teknikleri kullanılarak katılımcılardan veri toplanmasını gerektiren nitel ya da nicel yaklaşım bulunmadığından etik kurul onayı gerekmemektedir.

\* Doç.Dr. Jandarma ve Sahil Güvenlik Akademisi, Jandarma ve Sahil Güvenlik Fakültesi, [hamit.erdal@jsga.edu.tr](mailto:hamit.erdal@jsga.edu.tr), ORCID: 0000-0001-8352-6427

\*\* Doç.Dr. Giresun Üniversitesi, Balıncak Uygulamalı Bilimler Yüksekokulu, Lojistik Yönetimi Bölümü, [selcuk.korucuk@giresun.edu.tr](mailto:selcuk.korucuk@giresun.edu.tr), ORCID: 0000-0003-2471-1950

(Makale Türü: Araştırma Makalesi)

## Giriş

Gerek bireysel gerekse kurumsal yatırımcıların amacı, finansal piyasaların hareketlerini analiz ederek, piyasa trendine göre mümkün olduğunca doğru bir tahmin yapmak ve bu tahmin doğrultusunda yatırım araçlarını kullanmaktır. Etkin piyasa hipotezi ve rastlantısal yürüyüş kuramına göre geçmiş alım satım değerlerine dayanarak hisse senedi fiyatlarının tahmin edilebileceği pek çok çalışmada vurgulanmıştır (Soni, 2011).

Finansal zaman serilerinin doğrusal olmayan, dinamik, karmaşık ve kaotik yapısı nedeniyle, yüksek tahmin başarısı elde etmek oldukça zordur. Finansal zaman serilerinde en çok tahmin çalışması yapılan alanlardan biri de borsa endeks tahminidir. Borsa endeksleri yatırımcıların tercih ve beklentileri, ekonominin genel seyri, politik ortam ve değişimler, hatta sosyal medyaya bağlı oynaklık gibi pek çok mikro ve makro ekonomik faktörden etkilenmektedir (Pabuçcu, 2019).

Borsa endeks tahmini çalışmaları uzun yıllardır hem yatırımcıların hem de araştırmacıların ilgi odağı olmuştur. Analizlerin odağında uzun yıllar en uygun yöntemler olarak görülen temel ve teknik analizler 1990'lı yıllardan itibaren yerini daha bilimsel ekonometrik modeller ve istatistikî yöntemlere bırakmıştır. 2000'li yıllardan itibaren bu çalışmalar artan oranda yerini makine öğrenmesi ve zaman serisi analizlerine bırakmıştır (Atsalakis ve Valavanis, 2009; Soni, 2011). Son yıllarda ise yerini derin öğrenme modellerine bırakma eğilimi göstermektedir (Nti, vd., 2020; Jiang, 2021)

Makine öğrenmesi, bir karar destek sisteminin (ya da modelin), bir karar problem için çözüm üretebilmesi amacıyla geliştirilen yöntem ve algoritmalarını kapsayan bir yapay zekâ alt dalıdır. Derin öğrenme ise, çok daha büyük veri setlerinin özneliklerinin çıkarılması amacıyla geliştirilen, yapay sinir ağları tabanlı, çok katmanlı, bir yapay zekâ alt dalıdır (Elmas, 2022).

Evrişimsel Sinir Ağları (ESA)'nın çok katmanlı yapısı ile girdileri tek katmanlı yapay sinir ağları gibi klasik makine öğrenmesi yöntemlerine göre daha hızlı ve daha başarılı bir şekilde sınıflandırabildiği pek çok çalışmada raporlanmıştır (Ör: Cires vd., 2012; Aktaş vd., 2020; Ökten ve Yüzgeç, 2022).

Literatürde borsa endeks tahmini için bu çalışmada kullanılan ESA yönteminin son yıllarda probleme uygulandığı ancak Dalgacık Dönüşümü (DD) ile önışlem sürecine tâbi tutulan başkaca bir örnek tespit edilememiştir. Bu yönüyle çalışmanın literatüre katkı sağlayacağı değerlendirilmektedir. Gerçekleştirilen derin öğrenme çalışmalarının bazılarında veri öznelik çıkarımının yapıldığı katman sayısı artırılarak verideki örüntünün rahatlıkla yüksek düzeyde belirlenebildiği ve herhangi bir veri önışleme sürecine ihtiyaç bulunmadığı belirtilmiştir (Ör;

Dingli ve Fournier, 2017; Xu ve Keselj, 2019). Ancak katman sayısının artırılması da belirli bir noktadan sonra frekans uyumlaması (tuning) problemine neden olmaktadır. Bu sorunun ortadan kaldırılabilmesi amacıyla veri öznitelik çıkarımı konusunda etkinliği pek çok çalışma da kanıtlanmış (Ör; Erdal vd., 2013; Wang ve Adeli, 2015; Namlı vd., 2016) bir ön işlem prosedürünün derin öğrenme yöntemlerine uygulanmasının tahmin performansına etkisi de ölçülebilmektedir. Derin öğrenme yöntemlerini uygulayan yazarlar tarafından katman sayısını artırmanın yanı sıra farklı ön işlem prosedürleri uygulanarak tahmin performansının hangi yaklaşımla daha yüksek bir düzeyde artırılabilmişinin tespit edilmesi ve uygulamanın bu doğrultuda yapılması gerektiği noktasında bir mahsuplaşma yapılmasının daha uygun olacağı değerlendirildiğinden bu çalışma gerçekleştirilmiştir.

Çalışmanın ikinci bölümünde öncelikle DD ve ESA yöntemleri tanıtılmış, ardından değerlendirme prosedürü olarak kullanılan çapraz-geçerlilik ile performans göstergeleri açıklanarak veri seti tanıtılmış, uygulamada kullanılan yazılım-donanım özellikleri hakkında kısaca bilgi verilmiş ve literatürde önceki borsa endeksi tahminleme çalışmalarında kullanılan yöntemler hakkında bir özet sunulmuştur. Üçüncü bölümde deneysel bulgular sunularak bu çalışmanın literatüre katkısı önceki çalışmalarla karşılaştırmalı olarak sunulmuş, tartışma ve ileride yapılacak çalışmalara önerilerin de bulunduğu sonuç bölümüyle çalışma tamamlanmıştır.

### Yöntem, Prosedürler ve Literatür İncelemesi

Bu bölümde, öncelikle çalışmada kullanılan DD ve ESA yöntemleri kısaca tanıtılacak, ardından problem için uygulanan prosedürler açıklanacaktır.

#### Dalgacık Dönüşümü

DD zaman serilerinin farklı frekans düzeylerinde alt serilere ayrıştırarak daha gürbüz bir davranış kalıbı sergilemesine ve daha güçlü bir tahmin başarısı elde etmeye olanak sağlayabilen bir ön işlem prosedürüdür (Taşçıkaraoğlu vd., 2016). Şekil 1.'de örnek olarak bir sinyalin dalgacık dönüşümünde kullanılan çözünürlük hücrelerinin görünümü sunulmuştur.



**Şekil 1: Bir Sinyalin Dalgacık Dönüşümünde Kullanılan Çözünürlük Hücreleri**

(Taşçıkaraoğlu vd., 2016'dan uyarlanmıştır.)

DD “ana dalgacık” olarak adlandırılan özgün fonksiyonun  $\psi(t)$  dönüştürülmesi ve genişletilmesiyle sinyalin aile fonksiyonlarına  $\psi_{a,b}(t)$  ayrılması işlemi olarak tanımlanabilir (Wang ve Adeli, 2015).

Herhangi bir  $f(t)$  fonksiyonun sürekli dalgacık dönüşümü,  $f(x)$  dalgacık dönüşümü alınacak işaret,  $\psi_{a,b}(t)$  dalgacık taban fonksiyonu ve  $W_f(a,b)$   $f(t)$ 'in dalgacık dönüşümünü sembolize etmek üzere Denklem (1)'de gösterildiği şekilde ifade edilebilir (Saravanan ve Ramachandran, 2010).

$$W_f(a,b) = \langle f, \psi_{a,b} \rangle = \int_{-\infty}^{\infty} f(x) \psi_{a,b}(x) dx \quad (1)$$

Sürekli dalgacık dönüşümündeki  $\psi_{a,b}(t)$  taban fonksiyonu,  $\psi(t)$  ana fonksiyonunun genişletme (ölçekleme-scale) ve öteleme (dönüştürme-translation) terimleri ile birlikte Denklem (2)'deki gibi tanımlanır (Erdal vd., 2013; Namlı vd., 2016).

$$\psi_{a,b}(x) = \frac{1}{\sqrt{a}} \psi\left(\frac{x-b}{a}\right) \quad (2)$$

Denklem (2)'de,  $a$  genişletme (scale),  $b$  ise dönüştürme (translation) parametreleridir. Fourier dönüşümü  $\Psi(s)$  olan,  $\psi(t)$  ana dalgacık fonksiyonunun gerçek-değerli bir fonksiyon olabilmesi için aşağıda ifade edilen onarırlık (admissibility) koşulunu (Denklem (3)) sağlamalıdır (Chalus vd., 2007).

$$C_\psi = \int_{-\infty}^{\infty} \frac{|\Psi(s)|^2}{|s|} ds \quad (3)$$

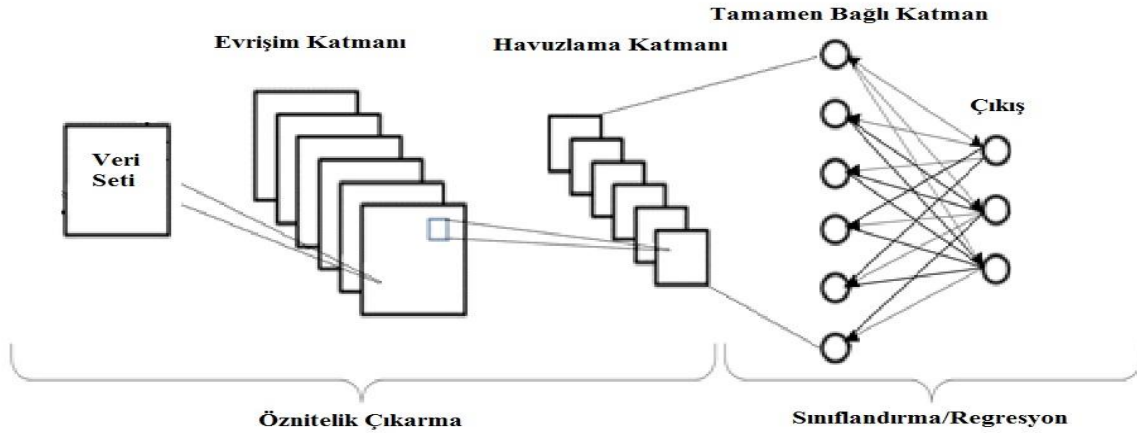
Bu işlemin ardından dönüşüm süreci yani veri ön işleme süreci tamamlanarak, zaman serileri farklı frekans düzeylerinde alt serilere ayrıştırılır ve verinin daha gürbüz bir davranış kalıbı sergilemesi, diğer bir deyişle daha güçlü bir tahmin başarısı elde edilmesi sağlanır.

**Evrişimsel Sinir Ağları**

ESA (ya da Konvolüsyonel Sinir Ağları-Convolutional Neural Networks-CNN), ızgara benzeri topolojiye sahip verilerin işlenmesi için etkili bir sinir ağı türü olup, canlı varlıkların doğal görsel algılama mekanizmasından esinlenilerek geliştirilmiş ve yaygın olarak kullanılan bir derin öğrenme mimarisidir (Jain vd., 2018).

Genel bir ESA mimarisi, evrişim katmanı, havuzlama katmanı, aktivasyon katmanı ve tamamen bağlı katman gibi probleme özgü çeşitli katmanlardan oluşmaktadır (Ökten ve Yüzgeç, 2022). Evrişim ve havuzlama katmanları, ağı oluşturmak için sıralı bir şekilde gömülür. Evrişim ve havuzlama işlemlerinin yapılması, sınıflandırmanın gerçekleştirildiği üst düzey özellikleri art arda oluşturur. Evrişim katmanı (convolution layer) yonteme adını veren katman olup, bu katmanda matematiksel işlemler ile girdi verisinin öznitelik haritalaması yapılır. Havuzlama katmanında (pooling layer) ağı modeli içerisindeki parametre ve hesaplama sayıları azaltıldığı gibi ağıdaki uyumsuzluklarda kontrol altına alınır. Aktivasyon katmanı (activation layer) model içerisindeki tüm katmanlardan sonra gelen ve doğrusal olmayan katmanı ifade eder. Bu katmanda doğrusal olmayan sigmoid, hiperbolik veya tanjant gibi fonksiyonlar kullanılabilir. Tamamen bağlantılı katman (fully-connected layer) ESA modelinin son ve en önemli katmanıdır. Bu katmanda sinir ağı ile sınıflandırma ve tanıma işlemi yapılmaktadır (Goodfellow vd., 2015). Şekil 2.'de örnek bir evrişimsel sinir ağı mimarisi sunulmuştur.


Şekil 2: Örnek bir evrişimsel sinir ağı mimarisi



Şekil 2: Örnek Bir Evrişimsel Sinir Ağı Mimarisi (Goodfellow vd., 2015'den uyarlanmıştır.)

### Değerlendirme Prosedürü

ESA modellerinin eğitilmesi sürecinde veri seti, eğitim ve test olarak iki gruba ayrılır. Modelin tahmin başarısı eğitim ve test veri setine bağlı olarak yüksek varyansa sahiptir (Elmas, 2021). Değerlendirme prosedürü olarak eğitim ve test veri setlerinin tüm veri setini temsil etmesi için çeşitli yöntemler geliştirilmiş olup, bu çalışmada üstünlüğü pek çok çalışmada kanıtlanmış (Ör: Yapraklı ve Erdal, 2015; Aydoğmuş vd., 2015; Erdal & Karahanoğlu, 2016; Erdal vd., 2018) 10-küme çapraz geçerlilik yöntemi kullanılmıştır. Bu yöntemde; Şekil 3'teki gibi veri seti 10 eşit kümeye bölünerek, 9 küme ile modeller eğitime tabi tutulmuş, kalan küme ile de test işlemi gerçekleştirilmiştir.



Şekil 3: 10 Küme Çapraz Geçerlilik Şematik Gösterimi

### Performans Göstergeleri

Önerilen modellerin tahmin başarı performanslarının belirlenebilmesi amacıyla yapay zekâ çalışmalarında yoğun olarak kullanılan korelasyon katsayısı (coefficient of correlation,  $r$ ), ortalama mutlak hata (mean absolute error, MAE) ve ortalama hata karesinin kökü (root mean square error, RMSE) göstergeleri kullanılmıştır.

Korelasyon analiziyle bağımlı değişken ile bağımsız değişken(ler) arasındaki ilişkinin doğrusallığı ve kuvveti hakkında bilgi edinilebilir.  $r$  değeri  $\pm 0$  ile 1 arasında bir değer alır. Değer 0'a yaklaşırsa modelin veriye uyum göstermediği veya bağımsız değişken(ler) ile bağımlı değişken arasında ilişki bulunmadığı, 1'e yaklaşırsa aralarında kuvvetli bir ilişki bulunduğunu gösterir. Doğrusallığı ( $\pm$ ) ise ortaya çıkarılan ilişkinin doğrusal olup olmadığını gösterir. Aşağıda Denklem (4-6)'da  $o_i$  ve  $t_i$  göstergelerin sırasıyla, tahmin sonuçlarını ve gerçekleşen değerleri ifade eder.  $N$  ise eğitim sayısını sembolize eder (Aydoğmuş vd., 2015; Uğur vd., 2019).

$$r = 1 - \frac{\sum_{i=1}^N (o_i - t_i)^2}{\sum_{i=1}^N (o_i - \hat{o}_i)^2} \quad (4)$$

MAE, tahmin değerleri ile gerçekleşen değerler arasındaki mutlak hatayı belirtir. Bu değer sıfıra yaklaştıkça, modelinin tahmin performansının o derece başarılı olduğu ifade edilir (Demirdöğen vd., 2017).

$$MAE = \frac{1}{N} \sum_{i=1}^I |o_i - t_i| \quad (5)$$

RMSE, tahmin değerleri ile gerçekleşen değerler arasındaki hata oranını belirlemek amacıyla kullanılmaktadır. MAE'ye benzer şekilde RMSE'nin de sıfıra yaklaşması, modelinin tahmin performansının o kadar başarılı olduğu ifade eder (Erdal, 2021).

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (o_i - t_i)^2}{N}} \quad (6)$$

## Veri Seti

Çalışmada, Borsa İstanbul (BIST) Sınai endeksi (XUSIN) günlük verisi kullanılmıştır. Bu kapsamda borsanın açık olduğu 5.000 günlük (31.12.2001-31.12.2021) endeks açılış fiyatları kullanılmıştır. Veri setine ait tanımlayıcı özet istatistikler Tablo 1’de sunulmuştur.

**Tablo 1: Veri Setine Ait Tanımlayıcı Özet İstatistikler**

Örneklem Sayısı	En Düşük Değer	1.Çeyreklik (Q1)	Ortanca (Q2)	Ortalama	3.Çeyreklik (Q3)
5.000	82,34	288,33	540,12	692,18	850,01
En Büyük Değer	Aralık (Q3-Q1)	Standart Sapma	Çarpıklık	Basıklık	Standart Hata
3.274,99	3.192,65	581,9	1,75	3,31	8,23

## Donanım ve Yazılım Ortamı

Çalışma kapsamında veri ön işleme sürecinde DD uygulaması için açık kaynak kodlu WEKA 3.8.5 yazılımından istifade edilmiştir. DD uygulaması sonrasında ESA modelinin kurulması ve çözülmesi amacıyla Python programlama dili kullanılmıştır. Bu aşamada özniteliklerin çıkarılmasında Keras, matematiksel işlemler için gerekli olan yapılar içinse numpy kütüphanesinden istifade edilmiştir.

Hesaplamalar için 4GB.’lık bütünleşik ekran kartına, i7-8550U işlemciye ve 20GB belleğe (RAM) sahip bir dizüstü bilgisayar kullanılmıştır.

## Literatür İncelemesi

Gerçekleştirilen literatür incelemesinde borsa endeksi tahmini konusunda son yıllarda yapılan çalışmaların dört yöntem grubu üzerinde odaklandığı tespit edilmiş olup, bunlar; (i) geleneksel makine öğrenmesi yöntemleri, (ii) bütünleşik makine öğrenmesi yöntemleri, (iii) zaman serileri analiz yöntemleri ve (iii) derin öğrenme yöntemleri olarak sıralanabilir (Nti, vd., 2020; Jiang, 2021; Soni vd., 2012). Bu kapsamda literatürde borsa tahmini çalışmalarında en yaygın kullanılan yapay zekâ yöntemlerinin bir özeti Tablo 2.’de sunulmuştur.

**Tablo 2: Borsa Tahmini Çalışmalarında En Yaygın Kullanılan Yapay Zekâ Yöntemleri**

Yöntem Grubu	Yöntem/Algoritma	Yayın
(i)	Doğrusal Regresyon (Linear Regression-LR) Lojistik Regresyon	Shah ve Bhavsar, 2015; Misra vd.,2018; Pahwa ve Agarwal, 2019 Dingli ve Fournier, 2017

	(Logistics Regression-Logit) Yapay Sinir Ağları (Artificial Neural Networks-ANN) Destek Vektör Makineleri (Support Vector Machines-SVMs) Naive Bayes Sınıflandırıcısı Genetik Algoritmalar-GA Sıralı Minimal Optimizasyon (Sequential Minimal Optimization-SMO)	Misra vd., 2018; Song ve Lee, 2019; Werawithayaset ve Tritilanunt, 2019 Shen vd., 2012; Misra vd.,2018; Kumar vd., 2018; Werawithayaset ve Tritilanunt, 2019; Pasupulety vd., 2019 Kumar vd., 2018 Sable vd., 2017 Werawithayaset ve Tritilanunt, 2019
(ii)	Rassal Orman (Random Forest-RF) Hızlandırılmış Karar Ağacı (Boosted Decision Tree-BDT) Aşırı Rassal Ağaçlar (Extremely Randomized Trees-ExtRa)	Manojlović ve Štajduhar, 2015; Misra vd.,2018; Kumar vd., 2018; Basak vd., 2019 Nayak vd., 2016 Pasupulety vd., 2019
(iii)	Otoregresif Hareketli Ortalama Modelleri (Autoregressive Integrated Moving Average- ARIMA) Otoregresif Koşullu Değişen Varyans Modelleri (ARCH-GARCH models)	Dong ve Gong, 2017; Patil vd., 2020 Effendi, 2015; Chen vd., 2017
(iv)	Evrişimsel Sinir Ağları (Convolutional Neural Network-CNN) Tekrarlayan Sinir Ağları (Recurrent Neural Network-RNN) Uzun-Kısa Süreli Bellek (Long Short-Term Memory-LSTM)	Dingli ve Fournier, 2017; Jain vd., 2018; Xu ve Keselj, 2019; Wang vd., 2021; Kirisçi ve Yolcu, 2022 Ding ve Qin, 2019; Muruganandham vd., 2021; Fayeem vd., 2022 Xingzhou vd., 2019; Xu ve Keselj, 2019; Shi vd., 2022

Borsa tahmini konusunda geleneksel makine öğrenmesi yöntemlerinin kullanılmaya başlanmasıyla beraber klasik ekonometrik yöntemlere göre tahmin başarısında ciddi oranda artış meydana gelmiş ve bu tarihlerden itibaren klasik ekonometrik yöntemlerin kullanımı önemli ölçüde azalmıştır (Kumar vd., 2018).

İlerleyen dönemlerde ise araştırmacılar tarafından farklı makine öğrenmesi yöntemlerinin bütünleştirilerek her birinin tek tek barındırdığı eksikliklerin kapatılabildiği ve hatta çok zayıf tahmin başarısı garantileyebildiği konusunda genel mutabakat bulunan yöntemlerin bile tahmin başarısında ciddi artış meydana geldiği tespit edilmiş ve daha güncel çalışmalarda bütünleşik makine öğrenmesi yöntemlerinden istifade edilmeye başlanmıştır. Bu yöntemler sayesinde borsa tahmini çalışmalarında önemli bir performans artışı tespit edilmiştir (Singh vd., 2019; Pasupulety vd., 2019).

Gerçekleştirilen zaman serileri analizleri incelendiğinde bu çalışmaların borsa endeks hareketlerini ve müşteri davranışlarına göre oynaklık tahmini üzerine odaklandığı belirlenmiştir (Effendi, 2015; Chen vd., 2017).

Derin öğrenme yöntemlerinin geliştirilmesinden itibaren tahmin çalışmalarının da derin öğrenme yöntemlerinin kullanımında ciddi oranda bir artış olduğu, özellikle yüksek hacim ve



anlık akış sağlayan verilerle gerçekleştirilen çalışmalarda derin öğrenme yöntemlerinin önemli ölçüde tahmin performansını artırdığı tespit edilmiştir. Bu nedenle derin öğrenmeye çok elverişli olan borsa verileriyle gerçekleştirilen çalışmalarda da artış yaşanmıştır (Kirisçi ve Yolcu, 2022).


Bu çalışmalara ilave olarak sosyal medya madenciliği ve metin madenciliği çalışmalarında yaşanan gelişmelere paralel olarak twitter, facebook gibi sosyal mecralardaki paylaşımlar ile blog ve haber sayfalarındaki müşteri paylaşımlarına göre hisse senedi tahmini ve oynaklık çalışmalarının da son yılların popüler araştırma sahaları olarak literatürde yer aldığı tespit edilmiştir (Ör; Huang ve Liu, 2020; Mehta vd., 2021; Valle-Cruz vd., 2022).

### Deneysel Bulgular


Önerilen yöntemlerin tahmin performanslarının değerlendirilmesi için 3 model oluşturulmuştur. Model 1.'de 1 gün geriden gelen değerlerle, Model 2.'de 3 gün geriden gelen değerlerle ve Model 3.'de ise 7 gün geriden gelen değerlerle tahmin yapılmıştır. Oluşturulan modeller için 10-küme çapraz-geçerlilik yöntemiyle veri seti eğitim ve test verisi olarak ayrıştırılmış ve eğitim verisiyle testler gerçekleştirilmiştir. ESA metodunun parametrelerinin seçimi tahmin performansını doğrudan etkilediğinden bu aşamada pek çok deneme sonrasında en iyi tahmin performansı öğrenme katsayısı  $L=0.3$ , moment  $M=0.2$ , eğitim sayısı  $N=1000$  ve gizli katman sayısı  $H=5$  ile elde edilmiştir. Her üç modelinde  $r$ , MAE ve RMSE performans göstergelerine göre elde edilen sonuçları Tablo 3'te ve Şekil 4-6 arasında sunulmuştur.

**Tablo 3: Modellerin Tahmin Performansları**


<b>Model 1: 1 Gün Geriden Gelen Değerlerle</b>			
	$r$	MAE	RMSE
ESA	0,9692	299,76	432,92
DDESA	<b>0,9794</b>	<b>228,09</b>	<b>345,33</b>
<b>Model 2: 3 Gün Geriden Gelen Değerlerle</b>			
ESA	0,9378	475,08	703,74
DDESA	0,9586	361,79	583,33
<b>Model 3: 7 Gün Geriden Gelen Değerlerle</b>			
ESA	0,9048	756,73	1096,11
DDESA	0,9164	600,03	911,08



Şekil 4: r Değerlerine Göre Modellerin Tahmin Performanslarının Radar Diyagramıyla Gösterimi



Şekil 5: MAE Değerlerine Göre Modellerin Tahmin Performanslarının Radar Diyagramıyla Gösterimi



**Şekil 6: RMSE Değerlerine Göre Modellerin Tahmin Performanslarının Radar Diyagramıyla Gösterimi**

Tablo 3. ile radar diyagramlarının incelenmesi neticesinde her üç model sonucunda da DD ile önışleme tabi tutulan DDESA yönteminin tahmin performansının ESA yöntemine göre daha iyi olduğu, Model 1'in yani 1 gün geriden gelen değerlerle yapılan tahminlemenin diğer modellere göre üstün olduğu tespit edilmiştir. Daha açık bir ifadeyle Model 1 ile yani 1 gün geriden gelen değerler ve DDESA yöntemiyle en yüksek tahmin başarısı elde edilmiş ve verilerin %97,94'ü doğru olarak tahmin edilebilmiştir. Model 1'i sırasıyla Model 2 ve 3 takip etmiştir. Benzer şekilde her üç performans göstergesine göre de elde edilen sonuçların uyumlu olduğu yani en yüksek r değerine sahip modelin en düşük MAE ve RMSE değeri sunduğu gözlenmiştir.

Aynı veri seti ile farklı tahminleme model ve yöntemlerinin kullanıldığı bir çalışma olmaması nedeniyle, bu çalışmanın sonucunda elde edilen tahmin performansları doğrudan bir başka çalışma ile karşılaştırılamamıştır. Ancak okuyuculara fikir vermesi ve önerilen model/yöntemlerin tahmin performanslarının üstünlüğünün ortaya konulabilmesi amacıyla benzer borsa endeks tahminleme çalışmalarının sonuçlarıyla da bir kıyaslama gerçekleştirilmiştir. Söz konusu çalışmalarda da bu çalışmalardan farklı performans göstergesi kullanıldığından sadece "r" değeri ile analiz sonucu paylaşılan çalışmaların en iyi tahmin performansı elde ettiği analiz sonuçları Tablo 4.'de sunulmuştur.

**Tablo 4: Literatürdeki Geçmiş Çalışmaların Tahmin Performansları**

Çalışma	Veri Seti	Önişlem Süreci	Yöntem	Tahmin Performansı

				(%)
Shen vd. (2012)	NASDAQ	+	SVMs	74,4
Manojlović ve Štajduhar (2015)	Zagreb Borsası	+	RF	80,8
Shah ve Bhavsar (2015)	NSE India	+	LR	90
Nayak vd. (2016)	BSE India	+	BDT	76
Sable vd. (2017)	NASDAQ	-	GA	73,87
Kumar vd. (2018)	NASDAQ	-	RF	79,87
Misra vd. (2018)	Karaçi Borsası	+	Logit	97
Basak vd. (2019)	AAPL	+	RF	78
	Çin Bileşen			
Ding ve Qin, 2019	Endeksi, PetroChina ve ZTE	-	RNN	97,37
Pasupulety vd., 2019	NSE India	-	ExtRa	95,42
Xu ve Keselj (2019)	NASDAQ	-	LSTM	65
	Çin Bileşen			
Wang vd. (2021)	Endeksi	-	ESA	97,28
Muruganandham vd. (2021)	NASDAQ	-	RNN	95,55
	Çin Bileşen			
Shi vd. (2022)	Endeksi	-	ARIMA	74,40
Shi vd. (2022)	Çin Borsası	-	ESA	88,34

Bu kapsamda literatürde;

(i) Geleneksel makine öğrenmesi yöntemlerinin kullanıldığı çalışmalarda tahmin başarısının %74,4-90 arasında olduğu, en fazla tahmin başarısının da, Logit yöntemiyle elde edilebildiği,

(ii) Bütünleşik makine öğrenmesi yöntemlerinin kullanıldığı çalışmaların görece olarak fazla olduğu, bunlar arasında da her ne kadar RF yöntemi ile en fazla sayıda yayında en iyi tahmin performansı elde edilse de bu başarının %80,8'i geçemediği, bütünleşik makine öğrenmesi yöntemlerinin kullanıldığı çalışmalar arasında en fazla tahmin başarısının ExtRa yöntemiyle %95,28 olarak elde edildiği,

(iii) Zaman serileri analiz yöntemleri kullanılarak tahmin performansının en yüksek ARIMA yöntemiyle %74,40 olarak elde edilebildiği,

(iv) Derin öğrenme yöntemlerinden bu çalışmada da kullanılan ESA ile RNN yöntemlerinin tüm literatürde en fazla tahmin başarısı sağlayan çalışmalar olduğu, bu çalışmada

elde edilen sonuca çok yakın olacak şekilde literatürde ESA yöntemiyle en fazla %97,28 oranında, RNN yöntemiyle de %97,37 oranında tahmin başarısı elde edildiği,

(v) Derin öğrenme yöntemlerinin kullanıldığı çalışmalarda önışlem prosesi kullanılmadığı tespit edilmiştir.

Tüm bu değerlendirmeler sonucunda her ne kadar aynı veri setinin kullanılmaması nedeniyle birebir karşılaştırma yapma imkânı bulunmasa da, bu çalışmada kullanılan DD yöntemiyle önışlem sürecine tabi tutulan ESA yöntemiyle %97,94 oranında tahmin başarı elde edilebilmiştir. Sadece ESA ve RNN yöntemlerini kullanan iki çalışmanın sonuçları bu çalışmanın tahmin başarısına son derece yakın olup, diğer çalışmalardan önemli ölçüde üstün tahmin performansı elde edilebilmiştir.

Borsa endeks tahmini için bu çalışmada kullanılan ESA yönteminin son yıllarda borsa endeks tahmini problemine uygulandığı ancak DD ile önışlem sürecine tâbi tutulan başkaca bir örnek tespit edilememesi çalışmanın literatüre sunduğu bir katkı olarak değerlendirilmiştir.

Literatürde gerçekleştirilen derin öğrenme çalışmalarının bazılarında veri öznetelik çıkarımının yapıldığı katman sayısı artırılarak verideki örüntünün rahatlıkla yüksek düzeyde belirlenebildiği ve herhangi bir veri önışleme sürecine ihtiyaç bulunmadığı belirtilmesine rağmen (Ör; Dingli ve Fournier, 2017; Xu ve Keselj, 2019), katman sayısının artırılması da belirli bir noktadan sonra frekans uyumlaması problemine neden olacağı da bilindiğinden bu sorunun ortadan kaldırılabilmesi amacıyla ilk defa bir önışlem prosedürünün derin öğrenme yöntemlerine uygulanmasının tahmin performansına etkisi de ölçülebilmştir.

Bu çalışmanın sonucunda elde edilen yüksek tahmin başarısı nedeniyle derin öğrenme yöntemlerini uygulayan yazarlar tarafından katman sayısını artırmanın yanı sıra farklı önışlem süreçleri uygulanarak tahmin performansının hangi yaklaşımla daha yüksek bir düzeyde artırılabilmişinin tespit edilmesinin de ortaya konulması gerekliliği tespit edilmiştir.

### **Sonuç ve Tartışma**

Bu çalışmada finansal zaman serileri analizlerinden üzerinde ulusal ve uluslararası alanda yaygın olarak çalışılan borsa endeksi tahmin problemi için Borsa İstanbul (BIST) Sınai endeksi (XUSIN) günlük verisi ile bir tahminleme çalışması yapılmıştır. Borsanın açık olduğu 5.000 günlük (31.12.2001-31.12.2021) endeks açılış fiyatları kullanılarak 3 model oluşturulmuştur. Model 1.'de 1 gün geriden gelen değerlerle, Model 2.'de 3 gün geriden gelen değerlerle ve Model 3.'de ise 7 gün geriden gelen değerlerle tahminleme yapılmıştır. Tahmin yöntemi ESA ve DD ile önışleme tabi tutulan ESA, yani DDESA yöntemleri kullanılmış ve DD'nin tahmin performansına etkisi araştırılmıştır.

Çalışmanın sonucunda her üç model sonucunda da DD ile önışleme tabi tutulan DDESA yönteminin tahmin performansının ESA yöntemine göre daha iyi olduğu, Model 1'in yani 1 gün geriden gelen değerlerle yapılan tahminlemenin diğer modellere göre üstün olduğu tespit edilmiştir. Benzer şekilde her üç performans göstergesine göre de elde edilen sonuçların uyumlu olduğu gözlenmiştir.

Genelde derin öğrenme yöntemleri için özelde ESA için bazı çalışmalarda öznetelik çıkarma işlemi için ayrı bir önışleme yöntemi uygulamaya gerek kalmadığı, derin öğrenmenin bu işlemi ađın eğitiminde kullanılan katmanlarda yaptığı belirtilmiştir (Ör: Ökten ve Yüzgeç, 2022). Ancak bu çalışmada olduğu gibi bazı çalışmalarda da önışlem ile beraber kullanılan ESA yönteminin tahmin performansında iyileşme tespit edilmiştir (Ör; Matiz ve Barner, 2019).

Sonuç olarak; DD'nin çok boyutlu doğrusal olmayan bir tahmin problemi olan borsa endeks tahmini probleminde etkin bir yaklaşım olduğu ve DD ile önışleme tabi tutulan ESA yönteminin (DDESA) finansal zaman serilerinin analizinde etkin olarak kullanılabileceđi tespit edilmiştir.

İleride yapılacak çalışmalarda; (i) bu çalışmada kullanılan veri seti ile farklı makine ve derin öğrenme yöntemleri kullanılarak karşılaştırmalı bir analiz yapılabilir, (ii) bu çalışmada tahmin performansının üstünlüğü raporlanan DDESA yönteminin literatürdeki diğer veri setlerine uygulanarak görelî etkinliđi araştırılabilir, (iii) günlük borsa endeks değerlerine etki ettiği değerlendirilen farklı deđişkenlerin modele etkisi araştırılabilir.

**Yazar Katkıları:** Yazarların katkı oranı aynıdır.

**Çıkar Beyanı:** Bu çalışmada çıkar çatışması bulunmamaktadır.

### Kaynakça

- Aktaş, A., Dođan B. ve Demir, Ö. (2020). Tactile paving surface detection with deep learning methods. *Journal of the Faculty of Engineering and Architecture of Gazi University*, 35(3), 1685-1700.
- Atsalakis, G.S. ve Valavanis, K.P. (2009). Surveying stock market forecasting techniques–part II: Soft computing methods. *Expert Systems with Applications*, 36(3), 5932-5941.
- Aydođmuş, H.Y., Ekinici, A., Erdal, H.İ. ve Erdal, H. (2015). Optimizing the monthly crude oil price forecasting accuracy via bagging ensemble models. *Journal of Economics and International Finance*, 7(5), 127-136.
- Aydođmuş, H.Y., Erdal, H.İ., Karakurt, O., Namlı, E., Türkan, Y.S. ve Erdal, H. (2015). A comparative assessment of bagging ensemble models for modeling concrete slump flow. *Computers and Concrete*, 16(5), 741-757.
- Basak, S., Kar, S., Saha, S., Khaidem, L. ve Dey, S. R. (2019). Predicting the direction of stock market prices using tree-based classifiers. *The North American Journal of Economics and Finance*, 47, 552-567.

- Chen, H., Xiao, K., Sun, J. ve Wu, S. (2017). A double-layer neural network framework for high-frequency forecasting. *ACM Transactions on Management Information Systems (TMIS)*, 7(4), 1-17.
- Cires, D.C., Meier, U., Masci, J., Gambardella, L.M. ve Schmidhuber, J. (2012). High performance convolutional neural networks for image classification. Proceedings of 22nd International Joint Conference on Artificial Intelligence, 1237-1242.
- Chalus, P., Walter, S. ve Ulmschneider, M. (2007). Combined wavelet transform-artificial neural network use in tablet active content determination by near-infrared spectroscopy. *Analytica Chimica Acta*, 591(2), 219-224.
- Demirdöğen, O., Erdal, H. ve Akbaba, A.İ. (2017). Comparing various machine learning methods for prediction of patient revisit intention: A case study. *Selçuk Üniversitesi Mühendislik Bilim ve Teknoloji Dergisi*, 5(4), 386-401.
- Ding, G. ve Qin, L. (2019). Study on the prediction of stock price based on the associated network model of LSTM. *International Journal of Machine Learning and Cybernetics*, 1-11.
- Dingli, A. ve Fournier, K.S. (2017). Financial time series forecasting—a deep learning approach. *International Journal of Machine Learning and Computing*, 7, 118-122.
- Dong, Y., Li, S. ve Gong, X. (2017, April). Time series analysis: an application of ARIMA model in stock price forecasting. In 2017 International Conference on Innovations in Economic Management and Social Science (IEMSS 2017), Atlantis Press, 703-710.
- Effendi, K.A. (2015). Determining the best ARCH/GARCH model and comparing JKSE with stock index in developed countries. *The Winners*, 16(2), 71-84.
- Elmas, B. (2021). Türkiye'deki kelebek türlerinin basamaklı evrişimli sinir ağları ile sınıflandırılması. *Konya Mühendislik Bilimleri Dergisi*, 9(3), 568-587.
- Elmas, B. (2022). Evrişimli sinir ağları ile mermer & granit çeşitlerinin transfer öğrenme yöntemiyle sınıflandırılması. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 37(2), 985-1002.
- Erdal, H. (2021). Prediction of pipeline projects construction costs utilizing machine learning techniques. International Marmara Science and Social Sciences Congress-IMASCON 2021 SPRING, 21-22 Mayıs 2021, Derince, Kocaeli.
- Erdal, H., Erdal, M., Şimşek, O. ve Erdal, H.İ. (2018). Prediction of concrete compressive strength using non-destructive test results. *Computers and Concrete*, 21(4), 407-417.
- Erdal, H. ve Karahanoğlu, İ. (2016). Bagging ensemble models for bank profitability: An empirical research on Turkish development and investment banks. *Applied Soft Computing*, 49, 861-867.
- Erdal, H.I., Karakurt, O. ve Namlı, E. (2013). High performance concrete compressive strength forecasting using ensemble models based on discrete wavelet transform. *Engineering Applications of Artificial Intelligence*, 26(4), 1246-1254.
- Fayeem, A., Kumar, A., Sagar, R., Aggarwal, A. ve Jain, D. (2022). Stock price prediction: Recurrent neural network in financial market. *International Journal for Modern Trends in Science and Technology*, 8(01), 259-264.
- Goodfellow, I., Bengio, Y. ve Courville, A. (2015). *Deep learning*. The MIT Press, Cambridge, Massachusetts, United States.
- Huang, J. Y. ve Liu, J. H. (2020). Using social media mining technology to improve stock price forecast accuracy. *Journal of Forecasting*, 39 (1), 104-116.

- Jain, S., Gupta, R. ve Moghe, A. A. (2018, December). Stock price prediction on daily stock data using deep neural networks. In 2018 International conference on advanced computation and telecommunication (ICACAT), IEEE, 1-13.
- Jiang, W. (2021). Applications of deep learning in stock market prediction: recent progress. *Expert Systems with Applications*, 184, 115537.
- Kirişçi, M. ve Yolcu, O. (2022). A new CNN-based model for financial time series: TAIEX and FTSE stocks forecasting. *Neural Processing Letters*, 1-18.
- Kumar, I., Dogra, K., Utreja, C. ve Yadav, P. (2018, April). A comparative study of supervised machine learning algorithms for stock market trend prediction. In 2018 Second International Conference on Inventive Communication and Computational Technologies (ICICCT), IEEE, 1003-1007.
- Manojlović, T., Štajduhar, I. (2015, May). Predicting stock market trends using random forests: A sample of the Zagreb stock exchange. In 2015 38th International Convention on Information and Communication Technology, Electronics and Microelectronics (MIPRO) (pp. 1189-1193). IEEE.
- Matiz, S., Barner, K. E. (2019). Inductive conformal predictor for convolutional neural networks: Applications to active learning for image classification. *Pattern Recognition*, 90, 172-182.
- Mehta, P., Pandya, S. ve Kotecha, K. (2021). Harvesting social media sentiment analysis to enhance stock market prediction using deep learning. *PeerJ Computer Science*, 7, e476.
- Misra, M., Yadav, A. P. ve Kaur, H. (2018, July). Stock market prediction using machine learning algorithms: A classification study. In 2018 International Conference on Recent Innovations in Electrical, Electronics & Communication Engineering (ICRIEECE), IEEE, 2475-2478.
- Muruganandham, R., Karthikeyan, M. S., Jagajeevan, R. ve Chitra, R. (2021). Deep learning-based forecast using RNN for stock price prediction. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, 12(14), 4939-4954.
- Namlı, E., Erdal, H.İ. ve Erdal, H. (2016). Dalgacık dönüşümü ile beton basınç dayanım tahmininin iyileştirilmesi. *Politeknik Dergisi*, 19(4), 471-480.
- Nayak, A., Pai, M. M., ve Pai, R. M. (2016). Prediction models for Indian stock market. *Procedia Computer Science*, 89, 441-449.
- Nti, I.K., Adekoya, A.F. ve Weyori, B.A. (2020). A systematic review of fundamental and technical analysis of stock market predictions. *Artificial Intelligence Review*, 53(4), 3007-3057.
- Ökten, İ., Yüzgeç, U. (2022). Evrişimli sinir ağı ile çeltik bitkisi hastalığının tespiti. *Bitlis Eren Üniversitesi Fen Bilimleri Dergisi*, 11(1), 203-217.
- Pabuçcu, H. (2019). Borsa endeksi hareketlerinin makine öğrenme algoritmaları ile tahmini. *Uluslararası İktisadi & İdari İncelemeler Dergisi*, 23, 179-190.
- Pahwa, K., Agarwal, N. (2019, February). Stock market analysis using supervised machine learning. In 2019 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COMITCon), IEEE, 197-200.
- Pasupulety, U., Anees, A. A., Anmol, S. ve Mohan, B. R. (2019, June). Predicting stock prices using ensemble learning and sentiment analysis. In 2019 IEEE Second International



- Conference on Artificial Intelligence and Knowledge Engineering (AIKE), IEEE, 215-222.
- Patil, P., Wu, C.S.M., Potika, K. ve Orang, M. (2020, January). Stock market prediction using an ensemble of graph theory, machine learning and deep learning models. Proceedings of the 3rd International Conference on Software Engineering and Information Management, IEEE, 85-92.
- Sable, S., Porwal, A., ve Singh, U. (2017, April). Stock price prediction using genetic algorithms and evolution strategies. In 2017 International conference of Electronics, Communication and Aerospace Technology (ICECA), Vol. 2, pp. 549-553). IEEE.
- Saravanan, N. ve Ramachandran, K. I. (2010). Incipient gear box fault diagnosis using discrete wavelet transform (DWT) for feature extraction and classification using artificial neural network (ANN). *Expert Systems with Applications*, 37(6), 4168-4181.
- Shah, A. ve Bhavsar, C. (2015). Predicting Stock Market using Regression Technique. *Research Journal of Finance and Accounting*, 6(8), 27-34.
- Shen, S., Jiang, H. ve Zhang, T. (2012). Stock market forecasting using machine learning algorithms. Department of Electrical Engineering, Stanford University, Stanford, CA, 1-5.
- Shi, Z., Hu, Y., Mo, G. ve Wu, J. (2022). Attention-based CNN-LSTM and XGBoost hybrid model for stock prediction. *Journal of Latex Class Files*, 14(8), 1-7, arXiv preprint arXiv:2204.02623.
- Singh, S., Madan, T. K., Kumar, J. ve Singh, A. K. (2019, July). Stock market forecasting using machine learning: Today and tomorrow. In 2019 2nd International Conference on Intelligent Computing, Instrumentation and Control Technologies (ICICICT), IEEE, 1, 738-745.
- Song, Y. ve Lee, J. (2019, December). Design of stock price prediction model with various configuration of input features. Proceedings of the International Conference on Artificial Intelligence, Information Processing and Cloud Computing, IEEE, 1-5.
- Soni, P., Tewari, Y. ve Krishnan, D. (2022). Machine learning approaches in stock price prediction: A systematic review. In *Journal of Physics: Conference Series*, IOP Publishing, 2161(1), 012065.
- Soni, S. (2011). Applications of ANNs in stock market prediction: a survey. *International Journal of Computer Science & Engineering Technology*, 2(3), 71-83.
- Taşçıkaraoğlu, A., Sanandaji, B. M., Poolla, K. ve Varaiya, P. (2016). Exploiting sparsity of interconnections in spatio-temporal wind speed forecasting using wavelet transform. *Applied Energy*, 165, 735-747.
- Uğur, L.O., Kanit, L., Erdal, H., Namlı, E., Erdal, H.İ., Baykan, U.N. ve Erdal, M. (2019). Enhanced predictive models for construction costs: A case study of Turkish mass housing sector. *Computational Economics*, 53 (4), 1403-1419.
- Valle-Cruz, D., Fernandez-Cortez, V., López-Chau, A. ve Sandoval-Almazán, R. (2022). Does twitter affect stock market decisions? financial sentiment analysis during pandemics: A comparative study of the h1n1 and the covid-19 periods. *Cognitive Computation*, 14 (1), 372-387.
- Wang, H., Wang, J., Cao, L., Li, Y., Sun, Q. ve Wang, J. (2021). A stock closing price prediction model based on CNN-BiSLSTM. *Complexity*, 2021 (1), 1-12.

- Wang, N., Adeli, H. (2015). Self-constructing wavelet neural network algorithm for nonlinear control of large structures. *Engineering Applications of Artificial Intelligence*, 41, 249-258.
- Werawithayaset, P., Tritilanunt, S. (2019, November). Stock closing price prediction using machine learning. In 2019 17th International Conference on ICT and Knowledge Engineering (ICT&KE), IEEE, 1-8.
- Xingzhou, L., Hong, R. ve Yujun, Z. (2019, July). Predictive modeling of stock indexes using machine learning and information theory. Proceedings of the 2019 10th International Conference on E-business, Management and Economics, IEEE, 175-179.
- Xu, Y. ve Keselj, V. (2019, December). Stock prediction using deep learning and sentiment analysis. In 2019 IEEE International Conference on Big Data (Big Data), IEEE, 5573-5580.
- Yapraklı, T.Ş. ve Erdal, H. (2015). Bankacılık sektöründe pazarlama karması elemanlarının önceliklerinin belirlenmesi: Erzurum ili örneği. *The Journal of Academic Social Science Studies*, 38, 481-500.