

**MUHASEBE VE FİNANS İNCELEMELERİ DERGİSİ**Dergi Anasayfası: <https://dergipark.org.tr/tr/pub/mufider>**BİST100 ENDEKSİNİN YAPAY SİNİR AĞLARI ve ARMA MODELİ İLE TAHMİNİ  
PREDICTION OF BIST 100 INDEX WITH ARTIFICIAL NEURAL NETWORKS AND ARMA  
MODEL****Lokman KANTAR<sup>a\*</sup>***a\* Sorumlu Yazar, Dr. Öğretim Üyesi, İstanbul Gelişim Üniversitesi, Uygulamalı Bilimler Yüksekokulu, Bankacılık ve Sigortacılık Bölümü, lkantar@gelisim.edu.tr, ORCID: 0000-0002-5982-6021***MAKALE BİLGİLERİ***Makale Tarihi:**Gönderilme Tarihi 23.04.2020**Düzenleme 18.05.2020**Kabul Tarihi 13.08.2020**Anahtar Kelimeler: BİST100 Endeksi, Geleneksel Zaman Serileri, Yapay Sinir Ağları  
Jel Kodları: C45, C53, G17***ARAŞTIRMA MAKALESİ****BENZERLİK/ PLAGIARISM***Ithenticate : %14***ARTICLE INFO***Article history:**Received 23.04.2020**Revised 18.05.2020**Accepted 13.08.2020**Keywords: BIST 100 Index, Traditional Time Series, Artificial Neural Networks  
Jel Codes: C45, C53, G17***ÖZET**

*Bireysel ve kurumsal yatırımcılar ile ekonomik faaliyette bulunan şirketler herhangi bir yatırım kararı vermeden önce geleceğe yönelik öngörü sahibi olmak isterler. Ülkelerin sermaye piyasalarını en iyi yansıtan göstergeler o ülkelerin borsası olması nedeniyle, ülkede faaliyette bulunan hisselerin performansları hakkında bilgi sahibi olmak isteyen yatırımcılar o ülkenin ekonomisini temsil eden borsa endekslerini takip ederler. Bu çalışmada BIST 100 endeksini 2009-2019 dönemi arasındaki aylık veriler kullanılarak makroekonomik çeşitli değişkenler ile tahmin edilmeye çalışılmış ve tahmin yöntemi olarak ARMA (1,1) modeli ile Yapay Sinir Ağları modeli kullanılmıştır. Modellere girdi değişkeni olarak Altın, döviz kuru sepeti, mevduat faizi, emisyon, doğrudan sermaye yatırımları, portföy yatırımları ve sanayi üretim endeksi verileri kullanılmıştır. Tahmin sonuçlarına göre Yapay Sinir Ağları modeli, ARMA (1,1) modeline göre daha yüksek bir performans göstermiştir.*

**ABSTRACT**

*Individual and corporate investors and companies engaged in economic activity want to have foresight before making any investment decision. The indicator that best reflects the capital markets of countries is the stock market indices of that country. Investors who want to be informed about the performance of the shares operating in the country follow the stock market indices representing the economy of that country. In this study, it has been tried to estimate BIST 100 index with various macroeconomic variables by using monthly data between 2009-2019 period and ARMA (1,1) model and Artificial Neural Networks model are used as prediction method. Gold, exchange rate basket, deposit interest, emission, direct capital investments, portfolio investments and industrial production index data were used as input variables. According to the estimation results, the Artificial Neural Network model showed a higher performance than the ARMA (1,1) model.*

## 1. GİRİŞ

2018 yılının ilk çeyreğinden itibaren Türkiye’de enflasyonun yükselmesi, önce Mayıs 2018 daha sonra Ağustos 2018 dönemlerindeki kurdaki yüksek volatilité ve belirsizlik geleceği öngörmenin önemini daha artırmıştır. Döviz kurlarındaki volatilitenin artması kısa sürede bir panik havası yaratmış ve gerek bireysel gerekse kurumsal yatırımcılar sahip oldukları menkul kıymetleri satarak alternatif yatırım araçlarına yönelmişlerdir. Kriz dönemlerinde meydana gelen bu spekülâtif hareketler nedeniyle yatırımcılar geleceği öngöremez bir duruma gelmektedirler.

Bireysel yatırımcılar ve kurumsal yatırımcılar geleceğe yönelik planlamalarında sahip oldukları ya da yatırım yapmak istedikleri menkul kıymetler ve çeşitli yatırım enstrümanları hakkında bilgi sahip olmak isterler. Bu nedenle bu yatırım enstrümanlarının gelecekteki hareketlerini önceden tahmin etmek son derece önemlidir.

BIST 100 endeksi Türkiye’nin ekonomik performansı açısından önemli bir gösterge kabul edildiği için BIST 100 endeksinin gelecekteki fiyat hareketlerinin tahmin edilmesi finansal yazın için her zaman cazip bir konu olmuştur. Geleceğe yönelik tahminler yapabilmek için çeşitli modeller geliştirilmiştir. Bunlardan bazıları basit regresyon modelleri, Box-Jenkins (ARMA) modeli, VAR (Vector Auto Regressive) modeli ile teknolojinin gelişmesi ile birlikte Yapay sinir ağları, Bulanık Mantık (Fuzzy Logic) ve Genetik Algoritma gibi esnek hesaplama tekniği olan modeller yumuşak tahmin modelleridir. (Aygören vd. 2012:74). Literatür incelendiğinde geleceğe yönelik tahminler de genellikle geleneksel yöntemler (ARMA vb.) ile Yapay sinir ağları gibi karmaşık modeller ile tahminler gerçekleştirilmiş ve yapay sinir ağları ile tahminlerin daha başarı olduğu gözlenmiştir. Bu nedenle bu çalışmada iki yöntem ile BIST 100 endeksinin tahmin edilip hangisinin üstün olduğu araştırılmıştır.

Bu çalışmada 2009-2019 yılları arasındaki tarihi verilerden yararlanılarak BIST 100 endeksinin tahmini, geleneksel yöntemlerden Box-Jenkins (ARMA) modeli ve yumuşak tahmin modelleri diye adlandırılan Yapay Sinir Ağları modeli ile tahmin edilecek ve sonuçları karşılaştırılacaktır.

## 2. LİTERATÜR İNCELEMESİ

Literatürde hisse senedi tahmini ile ilgili pek çok çalışma olup, çalışmaların bir kısmı hisse senedi fiyatı tahmini üzerine bir kısmı ise endeks tahmini üzerine yapılmıştır. Yapılan çalışmalarda genel olarak destek vektör makineleri, yapay sinir ağları gibi gelişen teknoloji ile yapılan tahminlerin geleneksel yöntemlere göre (arma vb.) daha başarılı sonuç verdiği gözlenmiştir. Yapılan literatür çalışmalarının özeti şu şekildedir;

Kutlu ve Badur (2009), BIST 100 endeksini 2 Temmuz 2001 ile 13 Temmuz 2006 tarihleri arasındaki verileri kullanarak ileri beslemeli yapay sinir ağları ile tahmin etmeye çalışmışlardır. Çalışma sonucunda, bir önceki günün endeks, Amerikan Doları ve gecelik faiz değişkenlerini girdi değişkeni olarak kullandıkları model BIST 100 endeksini 0,96 oranı gibi yüksek bir oranda tahmin etmişler ve bu yüksek R<sup>2</sup> değerleri BIST 100 endeksini ileri beslemeli yapay sinir ağları ile başarılı bir şekilde modellenebileceğini ifade etmişlerdir.

Aygören vd.(2012), BIST 100 endeksi ile ilişkili makroekonomik değişkenleri kullanarak geleneksel zaman serileri (ARMA), nümerik arama modelleri ve yapay sinir ağları yöntemleri ile tahmin etmeye çalışmışlardır. Çalışmalarında, 27.07.1995 ile 29.07.2010 tarihleri arasındaki 3779 adet günlük veri kullanmışlardır. Çalışma sonucunda, geleneksel zaman serileri ve Newton nümerik arama modelleri yapay sinir ağları tekniğine göre daha başarısız bir performans göstermiştir.

Erdoğan ve Özyürek (2012), 2011-2012 yılına ait haftalık veriler kullanarak yaptıkları çalışmada beyaz eşya sektöründe işlem gören hisse senetlerinin Cuma günü kapanış fiyatlarını Yapay Sinir Ağları modeli oluşturarak tahmin etmişlerdir. Hisse senedini etkileyen faktörler olarak dolar kuru, borsa endeksi, haftanın Pazartesi, Salı, Çarşamba, Perşembe günlerine ait kapanış fiyatları giriş katmanına giriş verileri olarak dahil edilmiş ve model sonucunda yapay sinir ağlarının hisse senetlerinin Cuma günü kapanış fiyatlarını yüksek oranda tahmin ettiği sonucuna ulaşmışlardır.

Ramavathu vd. (2012), çalışmalarında Hindistan çimento hisse senedi fiyat endeksi için Genetik Algoritma yöntemiyle altı iyi işlem kuralı belirlemişler ve bu işlem kuralları ile en yüksek getirinin elde edilebileceğini göstermişlerdir. Çalışma sonucunda diğer alım satım işlem kurallarına göre genetik algoritma ile belirlenen işlem kurallarının daha iyi performans gösterdiğini ortaya koymuşlardır.

Yakut vd.(2014), 2005-2012 dönemine ait tarihi verileri kullanarak BIST Endeksini yapay sinir ağları ve destek vektör makineleri ile tahmin etmeye çalışmışlardır. Çalışmada girdi değişkeni olarak BIST endeksinin bir, iki, üç gün öncesine ait değerler ile

Amerikan dolar kuru, gecelik faiz oranı, ve dünya finansal piyasaların önde gelen borsa endeksini modele dahil etmişlerdir. Çalışma sonucunda yapay sinir ağları ve destek vektör makinelerinin borsa endeksinin tahmininde iyi bir performans gösterdiği sonucuna ulaşmışlardır.

İlarslan (2014), çalışmasında bankacılık endeksine dahil olan on adet hisse senedinin 02.01.2012-31.12.2012 dönemine ait kapanış fiyatları kullanarak markov zincirleri kullanarak, hisse senetlerinin gelecekteki fiyat hareketlerini tahmin etmeye çalışmıştır. Çalışma sonucunda markov zincirleri yönteminin tahmin konusunda başarılı bir performans ortaya koyduğunu belirtmiştir.

Malakooti ve AghaSharif (2015), öğrenme ve eğri uyumluluğu süreci için yapay sinir ağları, optimizasyon süreci için genetik algoritmalar kullanılmasının ve tahmin aşamasında destek vektör makinelerinden yararlanılmasının doğru sonuçlar vereceğini ifade etmişlerdir. Son otuz günün tarihi verileri ve destek vektör makineleri ile NASDAQ %74,4, DJIA %77,6 ve S&P500 endeksi %76 oranında tahmin edilmiştir.

Çalışkan ve Deniz (2015), BIST 30 endeksinde yer alan şirketlerin 5 günlük fiyat ve fiyat yönü tahminini 2009-2014 dönemi için günlük veriler ile yapay sinir ağları tekniği ile gerçekleştirmişlerdir. Yapmış oldukları çalışma sonucuna göre BIST 30 endeksine ait 27 hisse senedi için fiyatlarda ortalama mutlak hata 21 kuruş, ortalama mutlak yüzde hata ise %1,80 olarak bulunmuştur. Yine hisse senetlerin fiyat yönü hareketleri %58 oranında doğru tespit edildiğini belirtmişlerdir.

Özçalıcı (2016), çalışmasında bir gün sonraki, iki gün sonraki, ve yirmi gün sonraki hisse senetleri fiyatlarını yapay sinir ağları tekniği ile tahmin etmiştir. Bist30 endeksinde yer alan hisse senetlerinin Ocak 2010- Kasım 2015 tarihleri arasındaki fiyat ve hacim bilgileri girdi değişkenleri olarak modele dahil edilmiş ve %72,88'e varan oranda yirmi gün önceden hisse senetlerinin fiyatlarının tahmin edilebildiğini belirtmiştir.

Telli ve Coşkun (2016), 29 Temmuz 2015- 15 Kasım 2015 tarihleri arasında BIST 100 endeksini yapay sinir ağları yöntemiyle tahmin etmeye çalışmışlardır. Girdi değişkeni olarak modele, enflasyon, faiz oranı, para arzı gibi değişkenlerin yanı sıra önemli politik gelişmeleri de dahil etmişler ve çalışmanın sonucunda endeksteeki volatilitayı ekonomik takvim etkinlikleri ve diğer değişkenlerin başarı ölçüde açıkladığını ifade etmişlerdir.

Özer vd. (2017), BIST 100 endeksi ile ilgili 2012-2016 yıllarına ait tarihi veriler ile Çin, Hindistan, Meksika, İstanbul, ABD, İngiltere, Almanya ve Fransa'daki endeksler modele girdi değişkeni olarak dahil edilip, yapay sinir ağları ve bulanık mantık teknikleri ile BIST 100 endeksi tahmin edilmiştir. Çalışma sonucunda az da olsa bulanık mantık tekniği

diğer yöntemlere göre daha iyi bir performans gösterdiğini ifade etmişlerdir.

Gündüz vd.(2017), İstanbul borsasında en çok işlem gören Garan, Thyao ve Isctr hisselerinin günlük fiyat değişimlerini derin sinir ağları yöntemiyle tahmin etmişlerdir. 2011-2015 dönemini kapsayan çalışma sonucuna göre derin yapay sinir ağları Garan hissesini 0.61, Thyao hissesini 0.578 ve Isctr hissesini 0.574 doğruluk oranıyla tahmin etmiştir.

Yiğiter vd. (2017), Borsa İstanbul'da işlem gören hisse senedi kapanış fiyatlarını regresyon yöntemi, bulanık mantık ve yapay sinir ağları yöntemiyle tahmin etmişlerdir. Veri seti olarak 2006-2016 haftalık kapanış fiyatları kullanılmıştır. Çalışma sonucunda bulanık mantık ve yapay sinir ağları yöntemlerinin regresyon yöntemlerine göre daha iyi performans gösterdiği sonucuna ulaşmışlardır.

Pabuççu (2019), BIST 100 borsa endeksinin negatif ve pozitif yönlü hareketlerini, yapay sinir ağı, destek vektör makinesi ve naive Bayes algoritması kullanarak tahmin etmeye çalışmıştır. Çalışmada veri seti olarak 2009-2018 yılları arasındaki günlük kapanış fiyatları ile işlem yapılmıştır. Çalışma sonucunda destek vektör makinelerinin en iyi sınıflandırıcı olduğu sonucuna ulaşılmıştır.

Bu çalışmada ise BIST 100 borsa endeksini etkilediği düşünülen girdi değişkenleri literatürde yapılan çalışmalardan farklı olarak Türkiye'nin bulunduğu ekonomik koşullarda dikkate alınarak daha da genişletilmiş ve geleneksel yöntemlerden Box-Jenkins (Arma) modeli ve Yapay sinir ağları modeli ile tahmin edilmeye çalışılarak tahmin sonuçlarının performansları karşılaştırılıp literatüre katkı sağlanması amaçlanmıştır.

### 3. YÖNTEM

#### 3.1. Zaman Serisi Verilerinin AR, MA ve ARIMA Modelleri

##### 3.1.1. Otoregressif Modeller (AR)

Bu modellerde değişkenlerin geçmiş dönem değerlerine bağımlılığı göz önüne alınarak tahmin modeli oluşturulur. Öncelikle otokorelasyon ve kısmi otokorelasyon katsayılarının dağılımı incelenmekte ve bu inceleme neticesinde otokorelasyon katsayılarının üstel olarak sıfıra yaklaştığı anlaşılırsa AR modellerinin söz konusu olduğu sonucuna varılmaktadır. AR modellerinin derecesini, istatistikî olarak sıfırdan farklı kısmi otokorelasyon katsayıları belirlemektedir.

Örneklem otokorelasyon veya kısmi otokorelasyon katsayılarının güven aralığı dışına düşmesi durumunda, katsayının gerçek değerinin sıfır olduğunu iddia eden  $H_0$  hipotezi reddedilir. Diğer taraftan tüm otokorelasyon katsayılarının aynı anda sıfır olduğunu iddia eden  $H_0$  hipotezinin test edilmesinde Q istatistiği kullanılır.  $H_0$  ortak hipotezinin reddedilebilmesi için

sadece bir tane otokorelasyon katsayısının istatistiki olarak sıfırdan farklı olması yeterlidir. Bununla birlikte her ne kadar tekil olarak otokorelasyon katsayısının istatistiki olarak sıfırdan farklı olduğu tespit edilmiş olursa da  $H_0$  ortak hipotezinin reddedilememesi söz konusu olabilmektedir.

$$y_t = \alpha * y_{t-1} + e_t \quad \text{AR}(1)$$

Bu modele göre  $y$ 'nin  $t$  dönemindeki değeri bir önceki dönemde aldığı değer ile rassal hata terimine (white noise) bağlıdır. Diğer bir ifadeyle bu modele göre  $y$ 'nin  $t$  dönemindeki kestirim değeri bir önceki dönem kendi değerinin bir oranı ve  $t$  dönemindeki rassal etkiye eşittir.

Modeli aşağıdaki gibi genelleştirebiliriz.

$$y_t = \alpha_1 * y_{t-1} + \alpha_2 * y_{t-2} + \dots + \alpha_k * y_{t-k} + e_t \quad \text{AR}(k)$$

Bu modellerde sadece  $y$ 'nin şimdiki ve önceki değerleri vardır. Diğer bir ifadeyle bu modellerde veri kendi adına konuşmaktadır.

Hata kareleri ortalamasını (veya toplamını) minimum yapan parametreler belirlenerek model oluşturulmaktadır. Parametrelerin istatistiki olarak sıfırdan farklı olduğu saptanırsa modelin tahminlerde kullanılabilir nitelikte olduğu sonucuna varılır. Son aşamada, seçilen modelle yapılacak tahmin hatalarının tesadüfiliği  $Q$  istatistikleri (Ki-kare testleri) yardımıyla araştırılır. Hatalar arasında bağımsızlık olduğu saptanırsa modelin uygunluğuna karar verilir (Brooks, 2008:215-223).

### 3.1.2. Hareketli Ortalama Modeli (MA)

Kısmi otokorelasyon katsayıları üstel olarak sıfıra yaklaşıyorsa zaman serisinin modellenmesinde hareketli ortalama modelinin uygun olduğu sonucuna varılır. MA modelinin derecesini, istatistiki olarak anlamlı otokorelasyon katsayıları belirler.

$$y_t = \theta + \beta_0 * e_t + \beta_1 * e_{t-1} \quad \text{MA}(1)$$

Bu modele göre  $y$ 'nin  $t$  dönemindeki değeri bir sabit terim ile şimdiki ve bir önceki dönem beyaz dizin (white noise) hata teriminin hareketli ortalamasının toplamına eşittir.

Modeli aşağıdaki gibi genelleştirebiliriz.

$$y_t = \theta + \beta_0 * e_t + \beta_1 * e_{t-1} + \beta_2 * e_{t-2} + \dots + \beta_k * e_{t-k} \quad \text{MA}(k)$$

Hata kareleri toplamı minimum olan parametreler belirlenerek model oluşturulmaktadır. Modelin parametrelerinin istatistiki olarak sıfırdan farklı olduğu belirlendikten sonra  $Q$  istatistiği hesaplanarak hataların birbirinden bağımsız olup olmadığı araştırılmaktadır. Hataların tesadüfi olduğu saptanırsa modelin tahminlerde kullanılabileceği sonucuna varılır (Brooks, 2008:211-215).

### 3.1.3. ARMA Modeli

$y$  değişkeni hem AR hem de MA özellikleri taşıyabilir. Bu durumda  $y$  değişkeni aşağıdaki gibi modellenir. Buna göre  $y_t$  değeri, önceki dönem değerleri ile cari ve önceki dönem white noise hata terimlerinin kombinasyonunun lineer fonksiyonudur.

$$y_t = \theta + \alpha_1 * y_{t-1} + \beta_0 * e_t + \beta_1 * e_{t-1} \quad \text{ARMA}(1,1)$$

Modeli ARMA (p,q) şeklinde genelleştirebiliriz. Bu durumda denklemde  $p$  tane ardışık bağlanım ve  $q$  tane hareketli ortalama terimi bulunur.

Yukarıda yer alan her üç model zaman serisinin durağan olduğu varsayımına dayanır. Zaman serisinin ortalaması, varyansı ve ortak varyansı zaman içinde değişmez ise o seri durağandır. Dolayısıyla yukarıda belirtilen yöntemlerin uygulanabilmesi için durağanlığı bozan trend ve mevsimsellik gibi unsurların bazı dönüşüm yöntemleriyle ortadan kaldırılarak serinin durağan hale getirilmesi gerekir (Brooks, 2008:223-230).

### 3.1.4. ARIMA Modeli

Bir zaman serisi durağan yapılabilmesi için  $d$  kez farkı alınır ve bu seri ARMA (p,q) yöntemi ile modellenir. Birinci dereceden bütünleşik olan bir zaman serisi ilk farkı alınarak durağan hale getirilebilir.

ARIMA (p,d,q):  $p$  ardışık bağlanım derecesini,  $d$  seriyi durağan duruma getirmek için kaç kez farkının alınması gerektiğini  $q$  ise hareketli ortalama derecesini gösterir. Buna göre ARIMA (2,1,2); zaman serisinin durağan olabilmesi için bir kez farkının alınması gerektiğini ve bu zaman serisinin iki AR ve iki MA terimiyle modellenebildiğini ifade eder. Zaman serisi başlangıçta durağan ise ARIMA (p,d,q) = ARMA (p,q) olur. ARIMA (p,0,0) ise bu zaman serisi sadece AR(p) modeli ile modellenebilir. Benzer şekilde ARIMA (0,0,q) ise bu zaman serisi sadece MA(q) modeli ile modellenebilir (Brooks, 2008:233).

Özet olarak Box-Jenkins yönteminin kullanılabilmesi için bir zaman serisinin durağan olması veya farkı alınarak durağanlaştırılması gerekir. Şayet zaman serisi durağan değilse suni otokorelasyonlar model belirlemeyi zorlaştıracaktır.

## 3.2. Yapay Sinir Ağları

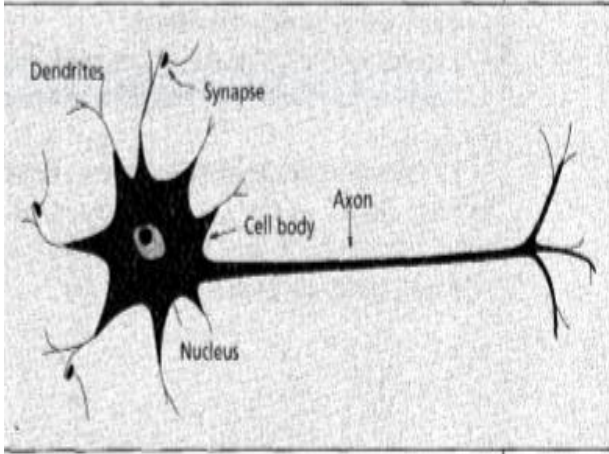
### 3.2.1 Yapay Sinir Ağlarındaki Tarihsel Gelişmeler

Yapay sinir ağları ile ilgili çalışmalar genel olarak üç dönemde yoğunlaşmaktadır. Bunlardan birincisi, 1940'lı yıllarda McCulloch ve Pitts'in öncülüğünü yapmış olduğu çalışmalarıdır (McCulloch ve Pitts, 1943:115). İkincisi 1960'lı yıllarda Rossenblatt'ın "Perseptron Yakınsama Teoremi" ve Minsky ve Papert'in basit bir perseptronun limitlerini gösteren çalışmalarıdır (Rossenblatt,1962; Minsky ve Papert,1969). Minsky ve Papert'in çalışmalarından elde ettiği bulgular yapay sinir ağları ile ilgili çalışma yapan bir çok araştırmacının hevesini kırmıştır (Jain vd. 1996:33). Minsky ve Papert'in çalışmasından yaklaşık yirmi yıl sonra 1982 yılında Hopfield'in ileri beslemeli öğrenme algoritması ile çok katmanlı perseptronlar ile yapmış olduğu enerji yaklaşımı yapay sinir ağları konusundaki önemli bir çalışma olarak kabul edilmektedir (Hopfield,1982:2554). Daha sonraları Werbos, Rumelhart 1986 yılında ve takibinde de Anderson ve Rosenfeld yapay sinir ağları

yaklaşımına önemli katkılar sunmuşlardır (Werbos, 1974; Rumelhart ve McClelland, 1986).

### 3.2.2 Yapay Sinir Ağları Mimarisi

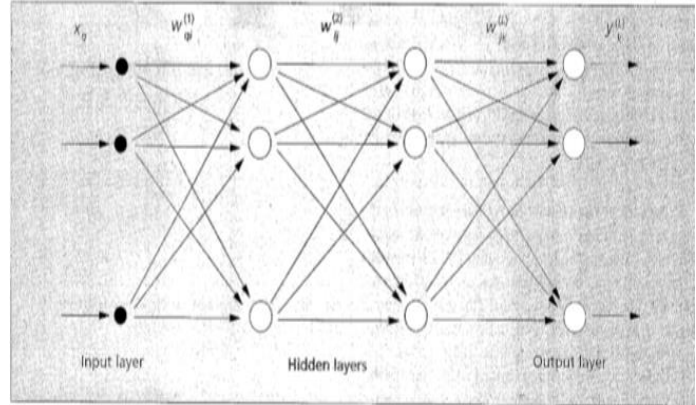
Yapay sinir ağları biyolojik sinir hücrelerinden esinlenmiştir. Biyolojik sinir hücresi hücre gövdesi (soma), dentritler, aksonlar ve sinapslerden meydana gelmektedirler. Sinapsler sinir hücreleri arasındaki bağlantılar olarak kabul edilmekle birlikte bunlar fiziksel bağlantılar olmaktan ziyade bir hücreden diğer hücreye elektrik sinyallerinin geçmesini sağlayan boşluklardır. Sinapslerden geçen sinyaller somaya geçer ve soma gelen verileri işleme tabi tutar. Sinir hücresi kendi elektrik sinyalini oluşturur ve akson aracılığıyla dentritlere gönderir. Dentritler ise bu sinyalleri tekrar sinapslere gönderir. İki hücrenin birbirleriyle alışverişleri nörotransmitterler yolu ile gerçekleşmektedir. Biyolojik bir hücre yapısı Şekil 1'de gösterildiği gibidir (Çalışkan ve Deniz, 2015:177-181).



Şekil 1. Biyolojik Hücre Yapısı

**Kaynak:** Jain, K. A, Mao, J. ve Mohiuddin, K.M.(1996), Artificial Neural Networks: A Tutorial s. 33

Yapay Sinir Ağlarının temel birimi işlem elemanı nöron veya düğüm olarak adlandırılan yapay sinir hücresidir. Yapay sinir ağlarında, çok sayıda işlem biriminin (nöron, düğüm veya yapay sinir hücresi) katmanlar halinde bir araya gelmesinden oluşur. Bu katmanlar giriş katmanı, gizli katman ve çıkış katmanından oluşmaktadır. Gizli katman sayısı bir veya daha fazla katmandan oluşabilmekte olup, birden fazla olması durumunda karmaşık problemlerin çözümünde oldukça yüksek performans göstermektedir. Çok katmanlı yapay sinir ağları Şekil 2'de gösterildiği gibidir:



Şekil 2. Çok Katmanlı Yapay Sinir Ağı

**Kaynak:** Jain, K. A, Mao, J. ve Mohiuddin, K.M.(1996), Artificial Neural Networks: A Tutorial, s. 38

Yapay sinir ağları, sinirler arası bağlantıların yönlerine göre ;

- ✓ İleri beslemeli ağlar (Feed-forward-network)
- ✓ Geri beslemeli ağlar (Recurrent/Feedback network)

İleri beslemeli ağlarda giriş katmanına verilen bilgi sürekli ileriye doğru hareket eder ve çıktı katmanından ağı çıktısı olarak çıkar. Geri beslemeli ağlarda ise en az bir yapay sinir hücresinin kendi katmanındaki veya kendinden önceki katmana dönüş bağlantısı bulunmaktadır (Çalışkan ve Deniz, 2015:177-181).

### 3.2.3. Yapay Sinir Ağlarında Öğrenme


Öğrenme, modelden istenilen işlevin (tahmin, optimizasyon vb.) yerine getirilebilmesi için ağdaki bağlantı ağırlıklarının ayarlanması işlemidir. Bu işlemler genellikle bilgisayar programları aracılığıyla (iterasyonlar) yapılmaktadır. Yapay sinir ağlarında öğrenmeler;

- ✓ Denetimli-danışmanlı (supervised) öğrenme,
- ✓ Denetimsiz-danışmansız (unsupervised) öğrenme
- ✓ Karma (hybrid) öğrenme

Şeklinde temel üç paradigmadan oluşmaktadır. Denetimli öğrenmede; ağa giriş vektörleri ve giriş vektörleri sonunda çıktı vektörleri girilir. Amaç çıktı vektörleri ile hedeflenen çıktı vektörleri arasındaki farkın minimum olmasıdır. Buradaki fark minimum olması için her bir iterasyonda girdi vektörlerinin ağırlıkları değiştirilerek ve bu işlem çıktı vektörleri ile hedeflenen çıktı vektörleri arasındaki fark minimum olana kadar devam edecektir. Hata fonksiyonu olarak en çok hata karelerinin ortalaması (Mean Squared Error-MSE) fonksiyonları kullanılmaktadır. Denetimsiz öğrenmede ise ağda çıktı vektörü yer almayıp bunun yerine ağdaki girdi vektörlerinin

birbirleri ile uyumu ve korelasyonu dikkate alınarak giriş vektörlerini sınıflandırılmaktadır. Karma öğrenme yönteminde ise ağırlıklar denetimli öğrenme yöntemi ile belirlenirken diğer öğrenme kuralları (girdi vektörleri arasındaki ilişkiler ve korelasyonlar) denetimsiz öğrenme tarafından belirlenmektedir.

Yapay sinir ağlarında öğrenmeler çeşitli algoritmalar tarafından gerçekleştirilmektedir. Bu işlem eğitim ve test olmak üzere iki aşamada gerçekleştirilmektedir. Eğitim verileri ile elde edilen hatalar ile test verilerinden elde edilen hataların birbirine yakın çıkması gerekmektedir. Eğer eğitim verileri ile test verileri arasında fark yüksek çıkarsa öğrenmenin gerçekleşmediği ezberlemenin gerçekleştiği anlaşılmaktadır (overfitting). Katman sayısının az olması ya da katmandaki veri sayısının az olması ise ağırlıklar üzerindeki öğrenmenin gerçekleşmesini zorlaştırmaktadır (underfitting). Ağdaki katman sayısı ve veri sayısı ile ilgili kesin bir sayı genellemesinin bulunmaması nedeniyle her problemde deneme yanılma yoluyla en uygun katman sayısı ve veri sayısının belirlenmesi gerekmektedir.



**Şekil 3. Genellenmiş Ağ ve Ezberlenmiş Ağ**

**Kaynak:** Yıldız, B.(2011), Finansal Analizde Yapay Zeka, 67 (Aktaran Çalışkan ve Deniz (2015))

Şekil 3'te görüldüğü gibi iyi genellemeye ulaşmış bir ağda test hatası ile eğitim hatası birbirine paralel gerçekleşirken, ezberlenmiş bir ağ da belirli bir noktadan itibaren test hatası ile eğitim hatası arasındaki fark açılmaktadır. Ezberlenmiş ağda hatalar belli bir süre sonra tekrar artış göstermeye başlamaktadır.

## 4.UYGULAMA

### 4.1. Veri Seti ve Değişkenler

Bu çalışmada Ocak 2009- Nisan 2019 dönemi

arasındaki aylık veriler kullanılmış olup, veriler Türkiye Cumhuriyet Merkez Bankası (TCMB), Elektronik Veri Dağıtım Sisteminden (EVDS) elde edilmiştir. Bağımlı değişken olarak Bist 100 borsa endeksi makroekonomik değişkenler yardımıyla tahmin edilmeye çalışılmış ve tahmin modellerinde EVViews 9 ve Matlab yazılımlarından yararlanılmıştır. Çalışmada kullanılan değişkenler ve kısaltmaları aşağıdaki gibidir:

**Tablo 1: Değişkenler ve Kısaltmaları**

Değişken Adı	Kısaltması
Borsa İstanbul 100 Endeksi (Bağımlı Değişken)	BIST 100
Altın Ons Fiyatı	ALTIN
Mevduat Faizi	FAIZ
Euro-Dolar Döviz Kur Sepeti	KUR
Emisyon	EMISYON
Sanayi Üretim Endeksi	SUE
Doğrudan Sermaye Yatırımları	DSY
Portföy Yatırımları	PORTFOY

### 4.2. Verilerin Durağanlaştırılması

Değişkenler arasında ekonometrik olarak anlamlı ilişkiler elde edebilmek için serinin durağanlık koşulunu sağlaması gerekmektedir. Durağan serilerde dış şoklar uzun sürelerde ortadan kaybolmaktadır. Eğer durağan olmayan bir seri modele dahil edilirse normalde olmayan ilişki varmış gibi gözükür ve sahte regresyona neden olurlar (Sarıkovanlık vd. 2019:19). Çalışmada kullanılacak değişkenlerin sahte regresyona neden olmaması için durağan hale getirilmesi gerekmektedir. Bu nedenle değişkenlerin durağanlığı Augmented Dickey-Fuller Test sonuçlarına ve Schwarz bilgi kriterine\* göre sınımlanmıştır.

Schwarz bilgi kriterine göre sınımlanan Augmented Dickey-Fuller Birim Kök Test Sonuçları tablo 2'de gösterilmiştir.

**Tablo 2: ADF Birim Kök Test Sonuçları**

Değişken	ADF t testi	Seviye Değeri
LOGBIST100	-3.505473***	I(0)
LOGALTIN	-8.719958***	I(1)


\* Değişkenlerin yıllık olması ve gözlem sayısının çok yüksek olmaması

nedeniyle Schwarz kriteri tercih edilmiştir.

LOGFAIZ	-6.642210***	I(1)
LOGKUR	-8.401959***	I(1)
LOGEMİSYON	-7.112465***	I(1)
LOGSUE	-3.467523**	I(0)
PORTFOY	-12.48259***	I(1)
DSY	-10.11065***	I(0)

Üst indisler \*\*\*, \*\*, \* sırasıyla %1, %5 ve %10 için anlamlı olduklarını ifade etmektedir.

Durağan hale getirilen değişkenlerin grafikleri şekil 4’te gösterilmiştir.



**Şekil 4. Durağan Hale Getirilmiş Değişkenlerin Grafikleri**

Test sonuçlarına göre BIST 100 ve Sue değişkeni seviye değerlerinde durağan olup birim kök içermemektedirler. Diğer değişkenlerin ise birinci dereceden farkı alınarak durağan hale getirilmiştir.†

Durağan hale getirilen bağımlı ve bağımsız değişkenlerin tanımlayıcı istatistikleri tablo 3’de ve değişkenlerin korelasyonları tablo 4’de gösterilmektedir.

**Tablo 3: Tanımlayıcı İstatistikler**

Değişken Adı	Ortalama	Standart Sapma
<b>BIST 100</b>	11.18590	0.289349
<b>ALTIN</b>	0.003174	0.034490
<b>FAIZ</b>	0.002199	0.055067
<b>KUR</b>	0.009680	0.033074
<b>EMİSYON</b>	0.011556	0.042612
<b>SUE</b>	4.497047	0.206991
<b>DSY</b>	-4.162602	424.1562
<b>PORTFOY</b>	13.52846	848.4302

**Tablo 4: Değişkenler Arası Korelasyon**

	BIST 100	DSY	PORTFOY	ALTIN	EMİSYON	FAIZ	KUR	SUE
<b>BIST 100</b>	1.000	0.037	0.036	-0.194	-0.079	0.292	0.137	0.855
<b>DSY</b>	0.037	1.000	0.069	-0.093	-0.115	-0.047	-0.032	0.016
<b>PORTFOY</b>	0.036	0.069	1.000	-0.072	0.057	0.076	0.022	0.037
<b>ALTIN</b>	-0.194	-0.093	-0.072	1.000	0.131	-0.099	-0.103	-0.283
<b>EMİSYON</b>	-0.079	-0.115	0.057	0.131	1.000	-0.116	0.275	-0.122
<b>FAIZ</b>	0.292	-0.047	0.076	-0.099	-0.116	1.000	0.242	0.354
<b>KUR</b>	0.137	-0.032	0.022	-0.103	0.275	0.242	1.000	0.195
<b>SUE</b>	0.855	0.016	0.037	-0.283	-0.122	0.354	0.195	1.000

Değişkenlerin korelasyonları incelendiğinde değişkenler arasında çoklu doğrusal bağlantıya neden olacak bir ilişki görülmemiş tüm değişkenler tahmin için oluşturulacak modellere dahil edilebilecektir.

† Değişkenlerden Doğrudan Sermaye Yatırımları ile Portföy Yatırımları dışındaki değişkenlerin logaritması alınarak modele dahil edilmiştir. Bu

iki değişken ise negatif değerler içerdiğinden seviye değerinde modele dahil edilmiştir.

### 4.3 Yöntem ve Metoloji

Çalışmada bağımlı değişken olarak BIST 100 Endeksi kullanılmıştır. Çalışmada bağımlı değişken BIST 100 endeksi ARMA ve Yapay Sinir Ağları modeli ile tahmin edilecektir. ARMA(p,q) modeli için EViews 9, Yapay Sinir Ağları için Matlab R2017b paket programları kullanılmıştır.

#### 4.3.1 ARMA(p,q) Modeli İle Tahmin

Modelde yer alacak değişkenler durağan olduğu için ARIMA modeli yerine ARMA modelinin kullanılması daha uygundur. Bağımlı değişken BIST 100 endeksinin korelogramı incelendiğinde ARMA(1,1) modelinin kullanılmasının uygun olacağına karar verilmiştir. Kurulan model (Tablo 5) ve ARMA(1,1) modelinin tahmin sonuçları (Tablo 6) aşağıda verilmektedir.


**Tablo 5: Model Katsayıları ve t İstatistiği**

Değişken	Katsayı	Standart Hata	t-İstatistiği
C	5.6531	0.3381	16.7165
DSY	2.06E-05	3.32E-05	0.618841
PORTFOY	1.18E-06	1.65E-05	0.071076
ALTIN	0.415753	0.425856	0.976276
EMİSYON	0.244549	0.354751	0.689355
FAİZ	-0.001946	0.278999	-0.006977
KUR	-0.334300	0.463382	-0.721436
SUE	1.230134	0.075136	16.37202

**Tablo 6: ARMA(1,1) Tahmin Edici Sonuçları**

R <sup>2</sup>	0.950123	Bağımlı Değişken Ortalaması	11.17765
Düzeltilmiş R <sup>2</sup>	0.948876	Bağımlı Değişken Standart Sapması	0.302448
Hata Kareleri Toplamı	0.561186	Akaike Kriteri (AIC)	-2.462254
Prob.(F istatistiği)	0.000000	Schwarz Kriteri (SIC)	-2.371277


Tablo 6'da gösterilen ARMA(1,1) model sonuçlarına göre R<sup>2</sup> değeri 0.95, MSE(Mean Squared Error) 0.004526, AIC -2.46, SIC -2.37 olarak gerçekleşmiştir. ARMA (1,1) modeli sonucuna göre elde edilen BIST 100, tahmin edilen değer BIST 100f ve artık değer (kalıntılar) grafiği Şekil 5'te verilmektedir.



**Şekil 5. Arma (1,1) Tahmin sonuçlarının Grafiği**

#### 4.3.2. Yapay Sinir Ağları Modeli ile Tahmin

Uygulamanın bu kısmında BIST 100 endeksi çıktı değişkeni olarak tanımlanmış ve bu değişken yedi açıklayıcı girdi değişken (DSY, PORTFOY, ALTIN, EMİSYON, FAİZ, KUR, SUE) ile ileri beslemeli iki katmanlı ileri yapay sinir ağları yöntemiyle tahmin edilmektedir.



**Şekil 6. Yapay Sinir Ağı Mimarisi**

Şekil 6'da gösterildiği gibi y(t) çıktı değişkeni (BIST 100 endeksi) açıklayıcı değişkenler ile ve BIST 100 endeksinin gecikmeli değerleri ile gizli katmanı ve çıktı katmanı adı verilen iki katmanlı bir sinir ağı modeli ile tahmin edilmiştir.

Tahmin işlemi yapılırken modele ilave edilen 123 adet değişkenin 87 adedi eğitim, 18'er tanesi de doğrulama ve test aşamasında kullanılmıştır. Model 10 adet gizli nöron ve 2 gecikme ile eğitime başlamıştır. En iyi performansın tercih edilmesinde kriter olarak R<sup>2</sup> ve



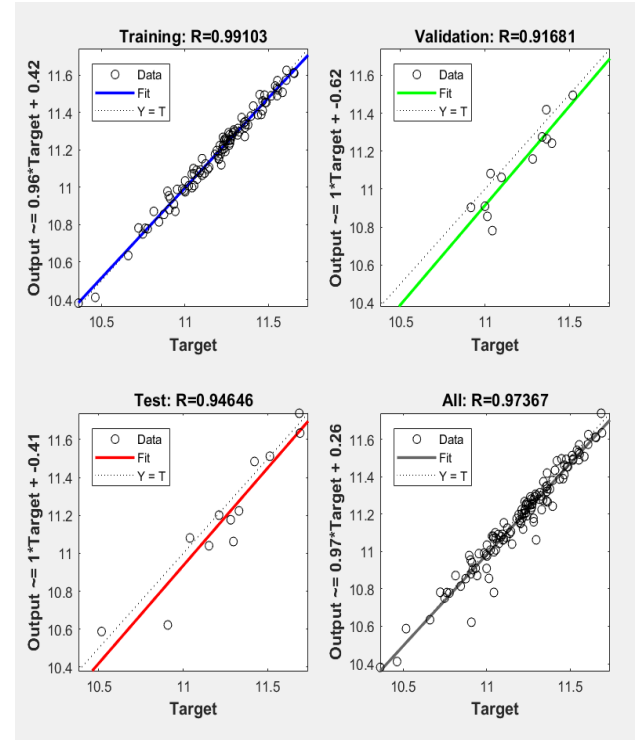
MSE değerleri dikkate alınmaktadır. Bu nedenle modelde nöron sayıları ve eğitim, doğrulama ve test oranları değiştirilerek en yüksek R<sup>2</sup> ve en düşük MSE değerini veren model en üstün tahmin modeli olarak kabul edilmiştir.

**Tablo 7: Yapay Sinir Ağları Model Tahmin ve Sonuçları**

I.Panel	Eğitim Oranı	Doğrulama Oranı	Test Oranı
	% 70	% 15	% 15
<b>10 Nöron</b>	<b>MSE</b>	<b>R<sup>2</sup></b>	
Eğitim	0.002554	0.9822	
Doğrulama	0.009030	0.9278	
Test	0.009965	0.9032	
<b>15 Nöron</b>	<b>MSE</b>	<b>R<sup>2</sup></b>	
Eğitim	0.001960	0.9862	
Doğrulama	0.007486	0.9572	
Test	0.001447	0.9233	
<b>20 Nöron</b>	<b>MSE</b>	<b>R<sup>2</sup></b>	
Eğitim	0.002441	0.9895	
Doğrulama	0.012469	0.9248	
Test	0.010516	0.9387	


II.Panel	Eğitim Oranı	Doğrulama Oranı	Test Oranı
	% 80	% 10	% 10
<b>10 Nöron</b>	<b>MSE</b>	<b>R<sup>2</sup></b>	
Eğitim	0.004408	0.9838	
Doğrulama	0.005663	0.9592	
Test	0.011097	0.9349	
<b>15 Nöron</b>	<b>MSE</b>	<b>R<sup>2</sup></b>	
Eğitim	0.002058	0.9850	
Doğrulama	0.005795	0.9011	
Test	0.01134	0.9448	
<b>20 Nöron</b>	<b>MSE</b>	<b>R<sup>2</sup></b>	
<b>Eğitim</b>	<b>0.001316</b>	<b>0.9910</b>	
Doğrulama	0.013580	0.9168	
Test	0.015760	0.9464	

Tablo 7’ya göre en iyi tahmin modelinin %80-%10-%10 oranlarında 20 nöronlu modelin olduğu görülmektedir. Bu modelde en düşük MSE (0.001316) değeri ve en yüksek R<sup>2</sup> ( 0.9919) oranı elde edilmiştir. Modelin regresyon grafikleri Şekil 7’de gösterilmiştir.



**Şekil 7. Tahminlerin Regresyon Grafikleri**

Şekil 7’deki regresyon grafiklerinde en doğru tahminin X ve Y eksenlerine 45 derece açı yapan tahmin doğrusudur. Grafiklerden de anlaşılacağı gibi nihai modelde bu açığa yaklaştığı görülmektedir.



**Şekil 8. BIST 100 Endeksinin Yapay Sinir Ağları ile Tahmin Grafiği**

Şekil 8'deki modele çıktı değişkeni olarak girilen değerler ile hedeflenen çıktı değerleri arasındaki farkın (kalıntı) birkaç dönem dışında oldukça az olduğu gözlenmektedir.

#### 4.3.3 Tahmin Sonuçlarının Karşılaştırılması

BIST 100 endeksi, ARMA(1,1) modeline göre yapılan tahmin sonuçlarına göre  $R^2$  değeri 0.95 ve MSE değeri 0.004526 şeklinde bulunmuş olup, Yapay Sinir Ağları modelinde  $R^2$  değeri 0.99 ve MSE değeri 0.001316 şeklinde hesaplanmıştır. Bu sonuçlara göre BIST 100 endeksinin tahmininde Yapay Sinir Ağları modelinin daha iyi bir performans gösterdiği sonucuna ulaşılmıştır.

## 5. SONUÇ

Türkiye'de 2018 yılında Mayıs ayında ve Ağustos ayında döviz kurunda meydana gelen yüksek volatilité ile birlikte Türkiye Cumhuriyet Merkez Bankası gecikmeli de olsa faiz oranlarını yükseltmek durumunda kalmıştır. Faiz oranlarının yükselmesi ile birlikte şirketlerin fon bulma imkanı zorlaşmıştır. Bu gelişmeler borsaya kayıtlı olan şirketlerin hisselerinde düşüişlere neden olmuştur. Finansal sistemde meydana gelen bu gelişmeler neticesinde Türkiye'de sermaye piyasalarının önemli bir göstergesi olan BIST 100 endeksinin tahmin edilmesi son derece önemli bir konudur. BIST 100 endeksi, bu endeksi oluşturan hisselerin Türkiye ekonomisinin lokomotifi kabul edilen şirketlerin performanslarını yansıttığı için doğru tahmin edilmesi de her dönem önemini korumaktadır.

Yapılan çalışmada BIST 100 endeksi ve endeksi etkilediği düşünülen döviz kuru, altın fiyatları, faiz oranları, emisyon miktarı, sanayi üretim endeksi, doğrudan sermaye yatırımları, portföy yatırımları gibi makroekonomik değişkenler yardımıyla tahmin edilmeye çalışılmıştır. 2009-2019 dönemini kapsayan çalışmada, tahmin yöntemlerinden arma(1,1) ve yapay sinir ağları modeli ile yapılan tahmin sonuçlarına göre yapay sinir ağları modelinin geleneksel tahmin yöntemlerinden arma (1,1) modeline göre daha iyi bir performans gösterdiği sonucuna ulaşılmıştır.

Çalışmanın bulguları literatürde yapılan çalışmalar ile karşılaştırıldığında; Kutlu vd. (2009), Aygören vd.(2012), Erdoğan vd. (2012), Yakut vd. (2014), Çalışkan ve Deniz (2015), Telli ve Coşkun (2016), Gündüz vd.(2017), Yiğiter vd.(2017) çalışmalarında elde edilen bulguları destekleyici nitelikte sonuçlara ulaşılmıştır. Bu nedenle tahmin yöntemlerinde

geleneksel yöntemlerden ziyade yapay sinir ağları gibi esnek hesaplama özelliği olan ve yumuşak hesaplama teknikleri olarak da adlandırılan yöntemlerin kullanılması daha yararlı olacaktır. Bundan sonra yapılacak çalışmalarda geleneksel yöntemlerle esnek hesaplama tekniği ile yumuşak tahminleme yöntemlerini karşılaştırmaktan ziyade esnek hesaplama tekniği ile yumuşak tahminleme yöntemlerini (genetik algoritma, yapay sinir ağları vb.) kendi içlerinde en etkin yöntemin hangisi olduğu ile ilgili çalışmalar yapmak literatüre katkı sağlayacaktır.

## KAYNAKÇA

- Aygören, H., Sarıtaş, H. ve Morallı T. (2012). İMKB 100 Endeksinin Yapay Sinir Ağları ve Newton Nümerik Arama Modelleri ile Tahmini, Uluslararası Alanya İşletme Fakültesi Dergisi, 4 (1), 73-88
- Brooks, C. (2008). Introductory Econometrics for Finance, Second Edition, Cambridge University Press. ISBN-13 978-0-511-39848-3
- Çalışkan, M. M. T. ve Deniz, D. (2015). Yapay Sinir Ağlarıyla Hisse Senedi Fiyatları ve Yönlerinin Tahmini, Eskişehir Osmangazi Üniversitesi İİBF Dergisi, 10 (3), 177-194,
- Erdoğan, E. ve Özyürek, H. (2012). Yapay Sinir Ağları ile Fiyat Tahminlemesi, Sosyal ve Beşeri Bilimler Dergisi, 4 (1), 85-92
- Gündüz, H., Çataltepe, Z. ve Yaslan, Y. (2017). Derin Sinir Ağları ile Borsa Yönü Tahmini, 25 th Signal Processing and Communications Applications Conference (SIU)
- Hopfield, J. J. (1982). Neural Networks and Physical Systems with Emergent Collective Computational Abilities, in Proc. Nat'l Academy of Sciences, USA 79, 554-2588
- İlarıslan, K. (2014). Hisse Senedi Fiyat Hareketlerinin Tahmin Edilmesinde Markov Zincirlerinin Kullanılması: İMKB 10 Bankacılık Endeksi İşletmeleri Üzerine Ampirik Bir Çalışma, Journal of Yasar University, 9 (35), 6185-6198
- Jain, A. K. ve Mao, J. ve Mohiuddin, K. M. (1996). Artificial Neural Networks: A Tutorial,
- Kutlu, B. ve Badur, B. (2009). Yapay Sinir Ağları ile Borsa Endeksi Tahmini, Yönetim 20 (63), 25-40.
- Malakooti, M.V. ve AghaSharif, A. (2015). Prediction of Stock Market Index based on Neural Networks,

- Genetic Algorithms, and Data Mining Using SVD, The Proceedings of the International Conference on Digital Information Processing, Data Mining, and Wireless Communications, Dubai, UAE.
- McCulloch, W.S. ve Pitts, W. (1943). A Logical Calculus of Ideas Immanent in Nervous Activity, Bull Mathematical Biophysics, 5, 115-133
- Minsky, M. ve Papert, S. (1969). Perceptrons: An Introduction to Computational Geometry, MIT Press. Cambridge.
- Özçalıcı, M. (2016). Yapay Sinir Ağları ile Çok Aşamalı Fiyat Tahmini: Bist30 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 Ağları ile Borsa Endeks Tahmini: Gelişmiş ve Gelişmekte Olan Ülkeler Örneği, Hitit Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, 11 (1), 99-123
- Pabuçcu, H. (2019), Borsa Endeksi Hareketlerinin Tahmini: Trend Belirleyici Veri, Selçuk Üniversitesi Sosyal Bilimler Yüksekokulu Dergisi, 22 (1), 246-256
- Ramavathu N. L, Bairam, M. ve Govardhan, A. (2012). Prediction of Stock Market Index Using Genthic Algorithm, Computer Engineering and Intelligent Systems, 3(7), 162-171
- Rosenblatt, R.(1962). Principles of Neurodynamics, Spartan Books, New York.
- Rumelhart, D. E.ve McClelland, L. J. (1986). Parallel Distributed Processing: Exploration in the Microstructure of Cognition, MIT Press, Cambridge.
- Sarıkovanlık, V., Koy, A., Akkaya, M., Yıldırım, H.H.,ve Kantar, L. (2019). Finans Biliminde Ekonometri Uygulamaları, Seçkin Yayıncılık, Ankara.
- Telli,Ş. Ve Coşkun, M. (2016). Forecasting the BIST 100 Index Using Artificial Neural Networks with Consideration of the Economic Calendar, International Review of Economics And Management, 4 (3), 26-46
- 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, 19 (1), 139-157
- Werbos, P. (1974). Beyond Regression: New Tools for Prediction and Analysis in the Behavioral Sciences, PhD thesis, Dept. Of Applied Mathematics, Harvard University, Cambridge.
- Yiğiter, Ş.Y., Sarı, S. S. ve Başakın, E. E. (2017). Hisse Senedi Kapanış Fiyatlarının Yapay Sinir Ağları ve Bulanık Mantık Çıkarım Sistemleri ile Tahmin Edilmesi, Kahramanmaraş Sütçü İmam Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 7 (1), 1-22