

# KRİPTO PARA FİYATLARININ KLASİK VE YAPAY SINIR AĞI MODELLERİ İLE TAHMİNİ



Makale Gönderim Tarihi: 29.07.2018 Yayına Kabul Tarihi: 16.09.2019

Kafkas Üniversitesi  
İktisadi ve İdari Bilimler  
Fakültesi  
KAÜİBFD  
Cilt, 10, Sayı 20, 2019  
ISSN: 1309 – 4289  
E – ISSN: 2149-9136

Serkan ARAS  
Dr.Öğretim Üyesi  
Dokuz Eylül Üniversitesi  
İktisadi ve İdari Bilimler  
Fakültesi  
serkan.aras@deu.edu.tr  
**Orcid id:** 0000-0002-6808-  
3979

**ÖZ** | Günümüzde kripto para birimlerinin önemi gittikçe artmaktadır. Kripto para birimleri sanal oyun platformlarında kullanılırken, şu an pek çok kurum ve kuruluş tarafından ödeme aracı olarak kullanılmaktadır. Güvenlik risklerine karşı blockchain (Blok Zinciri) adı verilen algoritması ile üretimi sağlanmaktadır. Kripto para fiyatlarının doğru olarak tahmin edilmesi yatırımcı ve karar vericiler açısından büyük önem taşımaktadır. Bu çalışma kapsamında en çok kullanılan dört kripto para birimine (Bitcoin, Ethereum, Ripple, Litecoin) ait fiyat değerleri tahmin edilmiştir. Çoklu kırılma testinden yararlanılarak her seriye ait kırılmalar belirlenerek analiz genişletilmiştir. Ele alınan sanal para değerlerini doğru bir şekilde tahmin etmek amacıyla hem klasik zaman serisi modellerinden hem de üç farklı tür yapay sinir ağı modelinden faydalanılmıştır. Ayrıca elde edilen tahminler üzerinde basit birleştirilme teknikleri uygulanmıştır. Rassal yürüyüşün egemen olduğu bu seriler arasından, özellikle işlem hacmi ve bilinirliği en fazla olan Bitcoin sanal parasında rassal yürüyüş modelinden daha iyi sonuçlar elde edildiği gözlemlenmiştir.

**Anahtar Kelimeler:** Bitcoin, Zaman Serisi, Yapay Sinir Ağı

**JEL Kodu:** C22, C45, C53

**Alanı:** Ekonometri

**Türü:** Araştırma

**DOI:** 10.36543/kauibfd.2019.026

**Atıfta bulunmak için:** Aras, S. (2019). Kripto Para Fiyatlarının Klasik ve Yapay Sinir Ağı Modelleri ile Tahmini. *KAÜİBFD*, 10(20), 608-640.

# FORECASTING THE CRYPTOCURRENCY PRICE USING THE CLASSICAL AND ARTIFICIAL NEURAL NETWORKS MODELS



Kafkas University  
Economics and Administrative  
Sciences Faculty  
KAUJEASF  
Vol. 10, Issue 20, 2019  
ISSN: 1309 – 4289  
E – ISSN: 2149-9136

Article Submission Date: 29.07.2018 Accepted Date: 16.09.2019

Serkan ARAS  
Asst.Prof.  
Dokuz Eylül University  
Faculty of Faculty of  
Economic and  
Administrative Sciences  
serkan.aras@deu.edu.tr  
**Orcid id:** 0000-0002-6808-  
3979

**ABSTRACT** Cryptocurrencies are increasing in importance. While to start with they were used only in virtual reality platforms for games, nowadays they are being used by many institutions and organisations as payment instruments. Against security risks, they are produced by an algorithm called blockchain. Predicting cryptocurrencies as accurately as possible is of great importance for investors and decision makers. In the scope of this study, the prices of the most-used four cryptocurrencies (Bitcoin, Ethereum, Ripple, Litecoin) are forecast. The analysis conducted is expanded by determining the break points of each series under investigation via the multiple break point test. For the purpose of predicting the concerned series, both classical time series models and three different artificial neural networks models are employed. In addition, the combining methods are carried out to improve the results. Among these random walk-dominated series, the best results are obtained with Bitcoin, which is the most widely known and has the highest trading volume, compared with other cryptocurrencies in the study.

**Keywords:** Bitcoin, Time Series, Artificial Neural Networks

**Jel codes:** C22, C45, C53  
**Scope:** Econometrics  
**Type:** Research

**Cite this Paper:** Aras, S. (2019). Forecasting the Cryptocurrency Price Using The Classical and Artificial Neural Networks Models. *KAUJEASF*, 10(20), 608-640.

## 1. GİRİŞ

Dünya, son yıllarda birçok alanda dijitalleşmeye başlamıştır. Bu dijitalleşme sonucunda yeni para birimleri ve ödeme sistemleri meydana gelmiştir. Bu para birimleri kripto paralar olarak adlandırılmış ve Mali Eylem Görev Gücü tarafından şöyle tanımlanmıştır: “*Sanal para, dijital olarak işlem yapılabilen dijital bir değer temsilidir ve (1) bir değişim aracı; ve / veya (2) bir hesap birimi; ve / veya (3) bir değer deposu olarak işlev görür, ancak herhangi bir yargı alanında yasal ihale statüsüne (yani, bir alacaklıya ihale edildiğinde, geçerli ve yasal bir ödeme teklifine) sahip değildir.*” (FATF, The Financial Action Task Force, 2014). Kripto para birimleri herhangi bir merkeze bağlı değildir ve belirli bir ülkeye bağlı olmadığından, değeri merkez bankası tarafından kontrol edilmemektedir. Esas olarak, kripto para birimleri, belirli koşullar yerine getirilmedikçe hiç kimsenin değiştiremeyeceği bir veri tabanında sınırlı girdilerdir.

Kripto para birimlerinin oluşturulmasını düzenlemek ve bir merkez bankasından bağımsız olarak fon transferini doğrulamak için şifreleme tekniklerini kullanılmaktadır. Kripto para hesapları şifreli olduğundan, bu hesapların kime ait oldukları asla bilinmez ve denetlenemediği için herhangi bir kurum veya hükümetler tarafından kapatılma veya askıya alınma gibi bir riskle karşılaşma olasılığı yoktur. Bu özelliklerinden dolayı kripto paralar gerçek paralar gibi kişi ve kurumlar tarafından kullanılmaya ve dünya genelinde kabul görmeye başlamıştır. Ama bazı ülkelerde kara para aklama ve takip edilememesinden dolayı yasa dışı kabul edilmiştir. Son yıllarda birçok kripto para birimi oluşturulmuştur. Bunlar arasında ilk oluşturulan ve en popüler olanı Bitcoin (BTC) ‘dir. Bitcoin ‘in üretilebileceği maksimum miktar 21 milyon ile sınırlıdır. Günümüzde mevcut piyasada bulunan bitcoin miktarı yaklaşık 16.980.875 adet ve toplam piyasa değeri yaklaşık 134.989.975.239 Amerikan dolarıdır. (Coinmarketcap, 2018). Kripto paraların toplam piyasa değeri yaklaşık olarak 356.308.633.430 Amerikan doları, 24 saatlik piyasa hacmi 21.553.445.980 Amerikan dolarıdır. Bitcoin pazar hakimiyeti %39,44 ve aktif kripto para birimleri 894 adet, aktif pazar ise 10461 adet olarak bilinmektedir. (Kriptoparapiyasası, 2018).

Söz konusu işlem hacmi ve büyüyen pazar payı dikkate alındığında kripto paraların fiyatlarını doğru bir şekilde tahmin etmek yatırımcı ve politika üreticiler tarafından büyük bir önem arz etmektedir. Kripto paraların fiyatlarını tahmin etmeye yönelik literatürde sınırlı sayıda çalışma bulunmaktadır. Özellikle finansal veriler söz konusu iken rassal yürüyüş yönteminin başarısından dolayı, bu çalışmada hem rassal yürüyüş hem de yönlü rassal yürüyüş yöntemi basit

tahmin aracı olarak seçilmiştir. Bunun yanı sıra tarihsel olarak tahmin çalışmalarında yoğun şekilde kullanılmış, üstel düzeltme yöntemi ve ARIMA modelinden faydalanılmıştır. Son olarak, günümüzde nispeten daha sık kullanılan, esnek modelleme ve doğrusal olmama özelliği sebebiyle yapay sinir ağları bu çalışma kapsamında ele alınmıştır. Çalışmanın amacı, en çok kullanıma sahip dört kripto paraya ait günlük kapanış fiyatlarını hem klasik hem de tahmin çalışmalarında başarılı sonuçlar elde etmiş üç farklı yapay sinir ağı modeliyle tahmin etmektir. Bu amaca yönelik olarak, öncelikle çoklu yapısal kırılma testinden faydalanarak incelenen serilerdeki yapısal farklılıkların ortaya çıktığı tarihler belirlenmiştir. Özellikle yapay sinir ağına ait literatürden bilindiği üzere, model oluşturmada kullanılacak veri hacmine ilişkin bir belirsizlik söz konusudur (Kaastra & Boyd, 1996; Zhang, Patuwo & Hu, 1998). Bir görüş, yapay sinir ağlarının güçlü modelleme yeteneklerine dayanarak yapısal kırılmaları dikkate almadan mevcut tüm veriden faydalanılmasını önermektedir. Diğer görüş ise, son dönem verilerinin gelecek gözlemler üzerinde etkisinin daha fazla olacağını ve son iki yıla ait verilerle daha iyi sonuçlar elde edilebileceğini iddia etmiştir (Walczak, 2001). Dolayısıyla, bu çalışmada kripto paralar üzerinde bu iki görüşün tahmin performansı üzerindeki etkisi incelenmiştir. Ele alınan her seri için, üç farklı modelleme yapılmıştır. İlk modelleme son kırılma sonrasında elde edilen verilerden, ikinci modelleme son iki yıla ait veriler üzerinde ve son modelleme ise eldeki tüm verilerin kullanılmasıyla gerçekleştirilmiştir. Bu farklı modelleme süreçlerinin faydalanılan modeller üzerinde etkisi, çeşitli hata ölçülerine dayanarak rapor edilmiştir.

Çalışmanın geri kalanı şu şekilde organize edilmiştir: Bölüm 2, kripto paralara yönelik yapılan çalışmalardan bahsetmektedir. Bölüm 3 'de Blok Zinciri hakkında ayrıntılı bilgi verilmiştir. Bölüm 4, yararlanılan yöntemlere ve veri setlerine ait açıklamalara yer vermiştir. Bölüm 5, elde edilen bulguları sunmaktadır. Son olarak, Bölüm 6 çalışmanın sonuçlarını içermektedir.

## 2. LİTERATÜR

Gronwald (2014) tarafından yapılan çalışma Bitcoin fiyatını analiz etmekte ve davranışları hakkındaki bilgileri derinleştirmeye çalışmaktadır. Analiz için GARCH modeli piyasadaki şoklardan kaynaklanan ciddi fiyat hareketlerini yakalamak için kullanılmıştır. Oluşturulan modelin verilere iyi uyum sağladığı ve aşırı fiyat hareketlerinin Bitcoin fiyatını karakterize ettiği tespit edilmiştir. Yelowitz ve Wilson (2015), Bitcoin kullanımının altında yatan gerekçeyi anlamak amacıyla Bitcoin topluluklarının 1133 üyesine anket yapmıştır. Anket sonucunda üç anahtar güdünün merak, kar ve politik olduğu belirlenmiştir. Bakar ve Rosbi (2017), Bitcoin getiri ortalamasının 0,006 ve sapmasının 0,04458

olduğunu göstermiştir. Bitcoin fiyatlarındaki oynaklığın %4.458 olduğunu ve bunun yüksek bir oynaklık olarak ele alınacağını belirtmiştir. Dolayısıyla bu yüksek oynaklık, Bitcoin 'e yönelik yatırımların yüksek risk taşıdığı anlamına gelmektedir. Buchholz vd. (2012), Bitcoin değişim piyasasında büyük bir piyasa balonunun mevcudiyetine işaret etmiştir. Yermack (2015), Bitcoin fiyatının tarihsel alım/satım davranışı üzerinde çalışmıştır ve Bitcoin 'nin bir para biriminden çok bir yatırım aracı olarak davranış gösterdiği sonucuna varmıştır. Indera vd. (2017), Bitcoin fiyatlarını doğru bir şekilde tahmin etmek amacıyla yapay sinir ağlarını kullanmıştır. Söz konusu çalışmada, iki farklı girdi türünden faydalanmıştır. İlk girdi türü geçmiş günlük fiyat değerlerinin açılış, kapanış, maksimum ve minimum değerlerinden oluşturulurken, ikinci girdi türü ise teknik göstergeler olarak farklı hareketli ortalama yapılarından oluşturulmuştur. Ağın parametreleri belirlenirken de parçacık sürü optimizasyonu tekniği kullanılmıştır. Elde edilen modelin Bitcoin fiyatlarını modelleyebilme yeteneği ortaya konmuştur.

Başka bir çalışmada, kripto paraların oynaklığı incelenmiştir (Catania & Grassi, 2017). Bu makalede piyasada en çok bilinen kripto paraların (Bitcoin, Ethereum, Litecoin ve Ripple) oynaklığı ele alınmıştır. Yapılan araştırmada, portföy optimizasyonundaki uygulamalarla oynaklığın modellenmesinin birincil öneme sahip olduğu türev menkul kıymetlerin korunması ve fiyatlandırılmasında kullanılabilmesi sonucuna varılmıştır. Hegazy ve Mumford (2016), kripto paraların artış veya azalış yönünü tahmin ederek al/sat stratejileri oluşturmuştur. En yüksek doğruluk oranına %57 ile makine öğrenme teknikleri aracılığıyla ulaşmışlardır. Literatür incelemesinde yer alan son makale, Bitcoin 'i yatırım veya spekülasyon bir araç olarak incelemiştir (Baek & Elbeck, 2015). Çalışmanın yazarları, Bitcoin fiyatını bazı ekonomik değişkenlerle (S&P 500 endeksi, tüketici fiyat endeksi, Euro döviz kuru ve diğer bazı ekonomik göstergeler) modellemeye çalışmışlardır. Analiz sonucunda, ekonomik değişkenlerin hiçbirinin Bitcoin fiyatına etki etmediği ortaya konmuştur. Araştırmacılar, Bitcoin 'nin spekülasyon bir araç olduğu ve fiyatının tüccarlar tarafından dahili olarak yürütüldüğü sonucuna varılmıştır.

Alessandretti vd. (2018) makine öğrenme yardımıyla alım-satım yaparak, etkin olmayan kripto para piyasasının anormal karlar elde etmede kullanılabilmesi hipotezini test etmişlerdir. Popüler makine öğrenme algoritmalarının yardımıyla basit alım-satım stratejilerinin standart yöntemlerden daha iyi sonuç verdiği ortaya koyulmuştur. Almeida vd. (2015) yapay sinir ağları bile Bitcoin üzerinde trend tahmini yaparak, kar elde etmede faydasını incelemiştir. Fiyata ilişkin yukarı, aşağı veya önemsizlik seviyesi şeklinde

çıktılar veren bir ağ inşa edilmiştir. Ağın çıktı katmanında bu üç durumdan hangisinin olasılığı yüksekse, buna bağlı olarak alım-satım kararı oluşturulmuştur. Mesela önemsizlik seviyesi tahmini üretilirse, alım-satım maliyeti kardan daha yüksek olacağından bir işlem yapılmayacaktır. Fiyat ve ticaret hacmi gecikmelerinin trendi etkilediği varsayılmıştır. Ancak günlük hacim verisinin girdi olarak alınması, sonuçları iyileştirmemiştir ve basit ağ yapıları karmaşık olanlara nazaran daha iyi sonuç vermiştir. Jang ve Lee (2017), Bayesci yapay sinir ağından makro ekonomik değişkenlere ek olarak blok zincirine ait bilgileri de değişken olarak modelleme sürecine katmada faydalanmışlardır. Amaç, birçok girdi değişkeni mevcut iken klasik sinir ağından ortaya çıkan aşırı uyum probleminden Bayesci ağda bulunan düzenleme (regularization) terimi ile kaçınmaktır. Bayesci sinir ağı, doğrusal regresyon ve destek vektör makinesi yönteminden hem daha iyi tahmin üretmiş hem de Bitcoin 'deki yüksek oynaklığı daha iyi açıkladığı görülmüştür. Karakoyun ve Çıbıkdiken (2018), gelecek 30 güne ait Bitcoin fiyatını tahmin etmek amacıyla ARIMA ve bir derin öğrenme algoritması kullanmıştır. Derin öğrenme algoritmasının ARIMA modeline üstünlük sağladığı tespit edilmiştir. Munim vd. (2019), sonraki gün Bitcoin fiyatlarını tahmin etmede ARIMA ve yapay sinir ağı modellerinden faydalanmışlardır. İki farklı eğitim ve test seti oluşturarak, ilk eğitim setinde sinir ağının ikinci eğitim setinde ise ARIMA 'nın daha iyi olduğu görülmüştür. Ayrıca her tahmin noktasında model parametrelerinin yeniden elde edilmesine dayanan karşılaştırmada, ARIMA modeli iki test setinde de daha iyi performans göstermiştir. Valencia vd. (2019) Bitcoin, Ethereum, Ripple ve Litecoin kripto paralarının fiyat hareketlerini tahmin etmek için makine öğrenme tekniklerinden yapay sinir ağı, destek vektör makinesi ve rassal orman (random forest) kullanmışlardır. Ayrıca sosyal medya (Twitter) ve pazar verilerini girdi olarak almışlardır. Elde edilen sonuç, makine öğrenme ve duygu analizinden (sentiment analysis) faydalanarak kripto paraları tahmin etmenin mümkün olduğunu göstermişlerdir.

### 3. BLOK ZİNCİRİ (BLOCKCHAIN)

Kripto paralar, herhangi bir hükümet, finansal kurum veya şirket tarafından kontrol edilmemekte ve gerçekte basılmamaktadır. Dijital paraları oluşturmak ve transfer etmek için kullanıcılarının merkezi olmayan ağını ve kriptografiden yararlanmaktadır. Bitcoin, 2008 yılında Satoshi Nakamoto (asıl ismi bilinmeyen kişi ya da grup) tarafından yazılan "Bitcoin: A Peer-to-Peer Electronic Cash System (P2P, uçtan uca)" adlı makaleyle ortaya çıkmıştır (Nakamoto, 2008). Nakamoto, Bitcoin sistemini herhangi bir aracı olmadan doğrudan işlem veya alışveriş yapma olarak tanımlamaktadır. Bir işlem gerçekleştiğinde, ağ düğümleri

bu işlemi doğrular ve blok zinciri içerisinde kayıt altına tutar. Blok zinciri, tüm işlemleri kayda geçen herkese açık merkezi olmayan hesap defteridir ve hesap tarihleriyle onlara karşılık gelen sanal para miktarlarını gösterir.

*Peer-to-Peer (P2P)*: Merkezi olmayan, merkezileştirilmemiş bir uçtan uca çalışan bir ağ yapısıdır. Bitcoin 'deki her parasal transfer bloklardan oluşan veri tabanlarına kaydedilir. Bitcoin 'de yapılan tüm işlemler blok zincirlerinden oluşup tüm transfer işlemleri dünyanın her tarafında bulunan tüm kullanıcılara (ağ içerisindeki) açıktır.

Bir kişi bir sanal para ile işlem yapmak istediğinde, bu kişinin işlem teklifi ağ içerisine yayılır ve işlemi onaylayacak kişi olan bir madenci bulur. Madenci işlem yapmak isteyen kişinin kişisel özel anahtarını kontrol ederek, bu kişinin hesabın sahibi ve yeterli miktar sanal parası olduğundan emin olur. Ardından, işlemi doğrular. Madenci blok zincir verisinin yardımıyla bilgileri kontrol eder. Oluşturulan algoritmalar blok zinciri içerisinde dolaşarak, sanal para geçmişini birden fazla harcamanın önüne geçmek için inceler. Madencinin onayı sonrasında, işlem yapan kişiye ait bilgi blok zincirine yeni bir zincir olarak eklenir. Her bir işlem sonrasında yeni zincirler eklenir ve madenciler bir bloğun doğrulanmasını ve geçmişini her zaman kontrol edebilir.

Bitcoin 'de parasal işlemleri yapabilmek için karmaşık matematiksel problemler çözülmek zorundadır. Bu matematiksel problemler “kriptografik bir hash fonksiyonu<sup>1</sup>” tarafından üretilmektedir. Bir işlemin doğrulanması süreci yaklaşık 10 dakika sürer ve oldukça maliyetlidir. Çok miktarda elektrik, özel ekipman ve uzmanlık gerektirir. İşlemlerin onaylanma sürecine “madencilik”, süreci gerçekleştiren kişiler “madenci” olarak tanımlanır. Bu giderleri karşılamak için madenciler karşılanmalıdır. Her başarılı işlem için madencilik, banka havalesi ücretlerinden oldukça düşük olan yeni Bitcoin ve işlem ücreti alır. Nakamoto tarafından oluşturulan algoritma tamamen 21 milyon Bitcoin yaratacaktır. Bunun 2140 yılında gerçekleşmesi beklenmektedir. (Yermack, 2015).

Günümüzde mevcut birçok kriptografik para bulunmaktadır. En yaygın olarak kullanılan Bitcoin üzerinde basit bir hash algoritması örneği aşağıdaki gibidir.

Hash Algoritması Verimiz <<bitcoin>> olsun. **bit | coin**

---

<sup>1</sup> “**Hash fonksiyonu**, değişken uzunluklu veri kümelerini, sabit uzunluklu veri kümelerine haritalayan algoritma veya alt programdır. Örneğin, bir kişinin ismi değişken uzunlukta ise, tekil tam sayı olarak **hash** edilebilir.

. bit >> b=2, i=9, t=20 >> 2+9+20=31  
 . coin >> c=3, o=15, i=9, n=14 >> 3+15+9+14=41  
 . 3+1=4 4+1=5  
 . 4=D, 5=E  
 .Bitcoin >> DE

Veri setini “Bitcoin” olarak aldıktan sonra, veri setinin adını hecelerine ayırarak her bir harf İngiliz Alfabesi ‘ne göre numaralandırarak her bir harf için karşılık gelen sayısal sıra değeri yazılıp ardından toplanır. Sayıları kendi içerisinde tekrar toplayarak çıkan sonuçların İngilizce Alfabesi ‘ndeki karşılıklarına bakarak Bitcoin ‘in karşılığı “DE” olarak özetlenmiştir. En büyük problemlerden biri de başka bir algorithmada bize “DE” sonucunu verebilir. Bu durumlarda çakışma yaşanmaktadır.

Bitcoin -kripto para birimi olmakla birlikte- güncel piyasa değeri, market hacmi ve kullanıcıları tarafından en çok talep gören sanal para birimidir. Tablo 1 ‘de görüldüğü üzere, Bitcoin ‘in yaklaşık piyasa değeri ve market hacmi diğer kripto para birimlerine göre oldukça yüksektir ve toplamsal olarak en fazla paya sahiptir. Bu çalışmada, Tablo 1 ‘de verilen kripto para birimleri incelenecektir.

**Tablo 1:** Piyasada İşlem Gören 4 Kripto Para Biriminin Güncel Piyasa Değeri ve Market Hacmi.

No	Kripto para birimi	Sembol	Güncel Piyasa Değeri (Amerikan doları)	Market Hacmi (Amerikan doları)
1	Bitcoin	BTC	8.875,64	150.885.658.109
2	Ethereum	ETH	631,39	62.543.891.783
3	Ripple	XRP	0,81	31.710.616.940
4	Litecoin	LTC	146,06	8.216.731.994

*Kaynak:* Kriptoparapiyasası (2018); Currencycalculate (2018).

#### 4. YARARLANILAN YÖNTEMLER ve VERİ SETİ

##### 4.1. Yapısal Kırılma Testi

Yapısal kırılma testleri ile ilgili literatürden bilinmektedir ki yapısal değişim uygulamalı zaman seri analizinde önemli bir rol oynamaktadır (Zeileis vd., 2003). Yapısal bir kırılma, model parametrelerini istenmeyen bir şekilde etkileyebilir. Yapısal kırılma içeren bir veri seti üzerine kurulan herhangi bir modelin tahmin performansı düşebilir. Harvey (1997), Clements ve Hendry (2001) yapısal kırılmaların birçok başarısız ekonomik tahminin nedeni olduğunu iddia etmiştir. Yapısal bir değişikliği saptamaya çalışan ilk testler, bilinen bir tarihte yapısal kırılma için test yapmak amacıyla  $F$  istatistiği kullanan Chow ‘a (1960) kadar uzanmaktadır. Bununla birlikte, kırılma tarihi önceden bilinmek



zorundadır ve bu durum Chow testinin zayıf noktasıdır. Önceden bir kırılma tarihinin bilinmesine ait zorluk, 1990 'lı yılların başında Quandt istatistiği için kritik değerler sağlayan Andrews (1993), Andrews ve Poleberger (1994) tarafından ortadan kaldırılmıştır. Böylece, incelenen zaman serisinin belirli bir tarihte kırılma bilgisi olmadan yapısal bir kırılmaya sahip olup olmadığı kolay bir şekilde tespit edilmiştir. Bir diğer zorluk, yapısal kırılma olmadığını söyleyen sıfır hipotezi reddedilirse çoklu yapısal kırılma olup olmadığını tespit edilmesiydi. Bu problem çoklu bilinmeyen kırılma noktalarını test eden Quandt Andrews planını geliştiren Bai (1997), Bai ve Perron (1998) tarafından çözüme kavuşturulmuştur. Yao (1988), Schwarz kriterinin kırılma sayısını tahmin etmede tutarlı olduğunu göstermiştir. Bu çalışmayı takiben, Liu vd. (1997) düzeltilmiş Schwarz kriteri (LWZ kriteri) kullanılmasını önermişler ve bu iddialarını desteklemek için detaylı simülasyon sonuçları sunmuşlardır. Bu çalışmada ilgilenilen serilerin yapısal kırılma sayısını belirlemek amacıyla bilgi kriterlerinden faydalanılmıştır. Test sonuçları ve bulunan tüm kırılma tarihlerine ilişkin ayrıntılar Bölüm 5 'de verilmiştir.

#### 4.2. Bazı Basit Tahmin Yöntemleri

Finansal verilerde rassal yürüyüşün egemen olduğu bilinen bir gerçektir. Bunun sonucu olarak ilk akla gelen yöntem, tahmin performansı oldukça güçlü olan rassal yürüyüş yöntemidir. Bu yöntemde, son gözlem değerinin gelecek gözlem değeri olacağı varsayılır.

$$\hat{y}_{T+h|T} = y_T \quad (1)$$

Rassal yürüyüş yönteminin bir diğer varyasyonu, tahminlerin zaman içerisinde artış veya azalışına imkan veren yönlü rassal yürüyüş metodudur. Burada zaman içerisindeki değişim miktarı tarihsel veride görülen ortalama değişim olarak alınır:

$$\hat{y}_{T+h|T} = y_T + \frac{h}{T-1} \sum_{t=2}^T (y_t - y_{t-1}) \quad (2)$$

Ayrıca bu analiz kapsamında basit bir model olması açısından, bir gecikmeli otoregresif model (AR(1)) ele alınmış ve incelenen veri setleri üzerinde performansı rapor edilmiştir.

#### 4.3. Üstel Düzeltme İçin Durum Uzay Modelleri

Üstel düzeltme yöntemleri basitliği ve karmaşık hesaplamalar gerektirmeme özelliği nedeniyle, elli yıldan fazla bir süredir kullanılmaktadır (Granger & Newbold, 2014). Üstel düzeltme yöntemleri, verinin iki bileşeninin ayrı ayrı belirlenmesine dayanmaktadır. Bu bileşenler trend ve mevsimselliklerdir.

Farklı trend ve mevsimsellik yapılarını dikkate katarak, beş trend bileşeni ve üç mevsimsel bileşen tanımlayarak on beş kombinasyon tanımlamak mümkündür. Her bir kombinasyon farklı bir üstel düzeltme yöntemine karşılık gelir. Bu yöntemler Tablo 2 'de bileşenlerinin formlarını belirleyen harf çiftleri ile (T,S) gösterilmiştir.

**Tablo 2.** Trend ve mevsimsellik bileşenlerinin tüm kombinasyonları.

Trend Bileşenleri (T)	Mevsimsel Bileşenler (S)		
	N (Yok)	A (Toplamsal)	M (Çarpımsal)
N (Yok)	N,N	N,A	N,M
A (Toplamsal)	A,N	A,A	A,M
$A_d$ (Toplamsal Sönümlü)	$A_d,N$	$A_d,A$	$A_d,M$
M (Çarpımsal)	M,N	M,A	M,M
$M_d$ (Çarpımsal Sönümlü)	$M_d,N$	$M_d,A$	$M_d,M$

Üstel düzeltme yöntemleri yıllardır kullanılmasına rağmen, son yeni metodolojik gelişmelerin ortaya çıkmasına kadar istatistiksel bir çerçeve içerisine yerleştirilememiştir. Ord vd. (1997) tarafından yapılan ve üstel düzeltme yöntemleri ile durum uzay formülasyonlarını ilişkilendiren çalışmayı takiben, Hyndman vd. (2002) var olan yöntemi genişletmiştir. Ele alınan tüm yöntemler için tahmin aralığı hesaplaması, model seçim kriteri ve en çok olabilirlik hesaplamaları sunmuştur. Bu yaklaşımın ayrıntılı teorik kapsamı, Hyndman vd. (2008) tarafından yazılan kitapta ele alınmıştır. Farklı durum uzay modellerini birbirinden ayırmak için ETS (Error-Trend-Seasonal) kısaltması kullanılır. Böylece, örneğin ETS (A,A,N) 'nin anlamı: modelin toplamsal hatalara sahip, toplamsal trenden oluşmuş ve mevsimsel olmamasıdır.

#### 4.4. ARIMA (Autoregressive Integrated Moving Average)

Box ve Jenkins (1970) tarafından gerçekleştirilen öncü bir çalışmada tanımlanan ARIMA modelleme prosedürü, zaman serisi tahmininde en yaygın olarak kullanılan doğrusal modellerden birisidir. ARIMA modelleri verideki otokorelasyon yapısının tespit edilmesine dayanır. Tahmin edilecek değişkenin, kendi gecikme değerleri ve hatalarının doğrusal kombinasyonunda oluştuğu varsayılır.

Mevsimsel olmayan bir ARIMA modeli aşağıdaki denklemle ifade edilebilir:

$$y'_t = c + \phi_1 y'_{t-1} + \dots + \phi_p y'_{t-p} + \theta_1 e_{t-1} + \dots + \theta_q e_{t-q} + e_t \quad (3)$$

burada  $y'_t$  ve  $e_t$ ,  $t$  zamanındaki farkı alınmış seriye ve rassal hataya karşılık gelmektedir. Denklem farkı alınmış serinin gecikmeli değerlerini ve hatalarını

eşitliğin sağ tarafında içermektedir.  $c$ ,  $\phi_i$  ( $i = 1, 2, \dots, p$ ) ve  $\theta_j$  ( $j = 1, 2, \dots, q$ ) model parametreleri,  $p$  ve  $q$  değerlerinin belirlenmesinin ardından tahmin edilir.

ARIMA ( $p, d, q$ ) gösterimi farklı modelleri temsil etmek için kullanılır.  $p, d, q$  sırasıyla otoregresif kısım derecesinin, fark alma derecesini ve hareketli ortalama derecesini gösterir. Uygun bir model belirlendikten sonra ( $p, d, q$  değerleri), ilgili modelin en çok olabilirliğini maksimize edecek şekilde parametreler tahmin edilir. Bu prosedüre ilişkin daha fazla bilgi için Montgomery vd. (2015) tarafından ele alınmıştır.

#### 4.5. Çok Katmanlı Algılayıcı (Multilayer Perceptron: MLP)

Yapay sinir ağı modeli insan beyninin paralel bilgi işleme yeteneğini taklit etmek amacıyla geliştirilmiş, sırasıyla girdi, gizli ve çıktı katmanlarından oluşan, veri sürürlü ve doğrusal olmayan yapıya sahip bir matematiksel modeldir. İlk sinir ağı modelleri sadece doğrusal problemleri çözebiliyorken, Rumelhart vd. (1986) önerdiği gizli katman hücreleri içerisine doğrusal olmayan fonksiyonlar yerleştirilmişken etkin bir öğrenme sağlayan geri yayılım (backpropagation) algoritması araştırmacıların büyük ilgisini çekmiştir. Yapılan çok sayıdaki başarılı uygulama, sinir ağlarının zaman serisi modelleme ve tahmin problemlerinde oldukça yararlı olduğunu göstermiştir (Zhang vd., 1998).

Tek gizli katmana sahip ileri beslemeli bir ağ, aşırı uyum sağlama (overfitting) probleminden kaçınmak amacıyla zaman serisi tahmin uygulamalarında sıklıkla tercih edilmektedir. Bu çalışma kapsamında, çok katmanlı algılayıcı (Multilayer Perceptron: MLP) olarak da bilinen ileri beslemeli ağ kullanılmıştır. Tek değişkenli zaman serisi tahmin probleminde, ( $y_t$ ) çıktısı ve ( $y_{t-1}, y_{t-2}, \dots, y_{t-p}$ ) girdileri arasındaki ilişkinin matematiksel formu aşağıdaki gibidir:

$$y_t = w_0 + \sum_{j=1}^q w_j f(w_{0j} + \sum_{i=1}^p w_{ij} y_{t-i}) + \varepsilon_t \quad (4)$$

Burada,  $w_0$  ve  $w_{0j}$  ( $j = 1, 2, \dots, q$ ) hücrelerdeki artıkları,  $w_j$  ( $j = 1, 2, \dots, q$ ) ve  $w_{ij}$  ( $i = 1, 2, \dots, p, j = 1, 2, \dots, q$ ) katmanlar arasındaki bağlantı ağırlıklarını,  $f(\cdot)$  gizli katmandaki transfer (aktivasyon) fonksiyonunu ve  $p$  ve  $q$  ise sırasıyla girdi ve gizli hücre sayısını göstermektedir.

Sinir ağı modeliyle zaman serisi tahmin uygulaması yapılırken, zaman serisinin otokorelasyon yapısını belirlemesiyle nedeniyle girdi (gecikme) hücre sayısının en önemli bileşen olduğu yapılan deneysel çalışmalarda gösterilmiştir (Zhang, Patuwo & Hu, 2001; Aras & Kocakoç, 2016). Bir diğer öneme sahip olan

bileşen ise gizli hücre sayısıdır. Gizli hücre sayısı, doğrusal olmama derecesine ve dolayısıyla da ağıın sahip olabileceği fonksiyonel esnekliğine etki etmektedir. Sinir ağı modellerinin arka planındaki matematiksel yapısını detaylı olarak ele alan Hagan vd. (1996) tarafından yazılan kitap incelenebilir.

#### 4.6. En Küçük Kareler Destek Vektör Makinesi (Least Squares Support Vector Machine: LS-SVM)

Destek vektör makinesi (SVM), Vapnik tarafından 1995 yılında istatistiksel öğrenme teorisine dayanarak önerilmiş (Vapnik, 1995) ve birçok araştırmacının dikkatini çekerek, zaman serisi tahmin problemlerinde umut vaat eden neticeler elde etmiştir (Müller vd., 1997; Tay & Cao, 2001; Kim, 2003). SVM başarılı uygulamalarına rağmen, kısıtlı optimizasyon programlama nedeniyle yüksek derecede bir hesaplama yüküne gerek duymakta ve oldukça zaman alıcı bir metot olma niteliği taşımaktadır. Bu nedenle, bahsi geçen zorlukların üstesinden gelmek amacıyla Suykens ve Vandewalle (1999) SVM 'nin geliştirilmiş versiyonu olan LS-SVM önerilmiştir. LS-SVM, eşitsizlik kısıtları yerine eşitlik kısıtlarını kullanmakta ve hesaplamalar açısından daha kolay olan, düzenlenmiş en küçük kareler kayıp fonksiyonundan yararlanmaktadır. LS-SVM, SVM 'nin önemli özelliklerine sahip olmasının yanında çok daha basit hesaplama yeteneğine sahiptir. Genelleme performansı açısından SVM ile kıyaslanabilir olduğu deneysel olarak gösterilmiştir (Wang & Hu, 2005).

Bu bölümde, regresyon amacına yönelik olarak LS-SVM tekniği kısaca verilmiştir.  $x_i$ ,  $i$ . örneğin girdisi ve  $y_i$  ise  $i$ . örneğin çıktısı iken  $N$  hacimli  $\{x_i, y_i\}_{i=1}^N$  eğitim seti olsun. LS-SVM yaklaşımıyla regresyon fonksiyonu şöyle ifade edilebilir (Suykens & Vandewalle, 2002):

$$f(x_i) = \mathbf{w}^T \phi(x_i) + b \quad (5)$$

Burada,  $\phi(x)$ ,  $x$  girdi uzayından yüksek boyutlu özellik uzayına doğrusal olmayan eşleşmeyi göstermektedir.  $w$  ve  $b$  ise aşağıdaki amaç fonksiyonunu minimize eden parametrelerdir.

$$J(\mathbf{w}, e_i) = \frac{1}{2} \mathbf{w}^T \mathbf{w} + \frac{1}{2} \gamma \sum_{i=1}^N e_i^2 \quad (6)$$

Burada,  $\gamma$  düzenleme (regularization) sabiti ve  $e_i$  ise eğitim seti hatasına karşılık gelmektedir. Bu amaç fonksiyonunun eşitlik kısıtları aşağıdaki gibidir:

$$y_i = \mathbf{w}^T \phi(x_i) + b + e_i \quad , \quad i = 1, \dots, N \quad (7)$$

SVM 'den farklı olarak eşitlik kısıtlıyla beraber, amaç fonksiyonuna  $e_i$

yerine  $e_i^2$  yerleştirilmiştir. Böylece, problemin çözümü daha kolaylaşmaktadır. Oluşturulan Lagrange fonksiyonu aşağıda verilmiştir:

$$L(\mathbf{w}, \alpha_i, b, e_i) = J(\mathbf{w}, e_i) + \sum_{i=1}^N \alpha_i [y_i - \mathbf{w}^T \phi(x_i) - b - e_i] \quad (8)$$

Burada,  $\alpha_i$  'ler Lagrange çarpanlarıdır. Optimallik için gerekli koşullar şöyledir:

$$\frac{\partial L}{\partial \mathbf{w}} = 0 \rightarrow \mathbf{w} = \sum_{i=1}^N \alpha_i \phi(x_i)$$

$$\frac{\partial L}{\partial b} = 0 \rightarrow \sum_{i=1}^N \alpha_i = 0$$

$$\frac{\partial L}{\partial e_i} = 0 \rightarrow \alpha_i = \gamma e_i$$

$$\frac{\partial L}{\partial \alpha_i} = 0 \rightarrow y_i - \mathbf{w}^T \phi(x_i) - b - e_i = 0 \quad (9)$$

$\mathbf{w}$  ve  $e_i$  'nin yok edilmesiyle çözüm, aşağıdaki doğrusal denklem sistemiyle elde edilir:

$$\begin{bmatrix} 0 & 1 & \dots & 1 \\ 1 & K(x_1, x_1) + \gamma^{-1} & \dots & K(x_k, x_k) \\ \vdots & \vdots & \ddots & \vdots \\ 1 & K(x_N, x_1) & \dots & K(x_N, x_N) + \gamma^{-1} \end{bmatrix} \begin{bmatrix} b \\ \alpha_1 \\ \vdots \\ \alpha_N \end{bmatrix} = \begin{bmatrix} 0 \\ y_1 \\ \vdots \\ y_N \end{bmatrix} \quad (10)$$

Burada,  $K(x_i, x_j) = \phi(x_i)^T \phi(x_j)$  çekirdek (kernel) olarak bilinir.  $\alpha_i$  ve  $b$  'nin doğrusal denklem sisteminin çözülmesiyle elde edilmesinin ardından, aşağıdaki nihai regresyon modeli ile çıktı değeri hesaplanır.

$$y(x) = \sum_{i=1}^N \alpha_i K(x, x_i) + b \quad (11)$$

Mercer 'in koşullarını (Mercer, 1909) sağlayan herhangi bir fonksiyon çekirdek fonksiyon olarak kullanılabilir. Bu çalışmada aşağıda verilen, radyal tabanlı fonksiyon (radial basis function) kullanılmıştır.

$$K(x_i, x_j) = \exp\left(-\frac{|x_i - x_j|^2}{2\sigma^2}\right) \quad (12)$$

Radyal tabanlı fonksiyonun çekirdek fonksiyon olarak kullanılması durumunda, elde edilen sonuçlar üzerinde önemli rol oynayan  $\sigma^2$  ve  $\gamma$  parametrelerinin belirlenmesi gerekir. Bu çalışmada, oldukça yaygın bir yaklaşım olan ızgara sisteminden (grid search) yararlanılmıştır (Hsu & Lin, 2002).

#### 4.7. Bulanık Çıkarım Sistemi Tabanlı Uyarlanabilir Ağ (Adaptive Network-based Fuzzy Inference System: ANFIS)

ANFIS, Jang (1993) tarafından önerilen bulanık mantık ile yapay sinir ağlarını birleştiren bir yaklaşımdır. Yapay sinir ağlarının girdi ve çıktı arasındaki karmaşık ilişkiyi öğrenme yeteneğiyle, bulanık mantığın belirsizlik ve gürültülü veri mevcutken insan bilgi ve çıkarım süreçlerinin çalışma yeteneğini birleştirmeye yönelik bir tekniktir. Bu birleştirme süreci ile beklenti, her iki tekniğin dezavantajlarının üstesinden gelmektir. ANFIS yaklaşımının çeşitli tahmin problemlerine uygulanarak, önemli sonuçlar elde edildiği literatürde mevcuttur (Boyacıoğlu & Avcı, 2010; Chang vd., 2011; Yazdani vd., 2012; Aras, Kocakoç & Polat, 2017).

ANFIS, farklı bulanık çıkarım sistemleri arasından çıktısı reel bir sayı olan Takagi-Sugeno sistemini kullanmaktadır. Bu tip çıkarım sistemi, iki çeşit parametre setinden oluşmaktadır. Bunlardan ilki; bulanık üyelik fonksiyonuna ait doğrusal olmayan öncül (antecedent) parametreler, ikincisi; çıktı fonksiyonuna ait doğrusal ardıl (consequent) parametrelerdir. ANFIS 'in kural tabanı, Takagi-Sugeno tipindeki bulanık Eğer-İse (IF-THEN) kurallarından faydalanır. Örneğin, iki kurallı Takagi-Sugeno bulanık çıkarım sistemi şöyle ifade edilebilir:

*Kural 1:* Eğer  $x$ ,  $A_1$  bulanık kümesinde ve  $y$ ,  $B_1$  bulanık kümesinde ise  $f_1(x,y)$  fonksiyonu

*Kural 2:* Eğer  $x$ ,  $A_2$  bulanık kümesinde ve  $y$ ,  $B_2$  bulanık kümesinde ise  $f_2(x,y)$  fonksiyonu

İki girdi ve bir çıktıdan oluşan ANFIS mimarisi, Şekil 1 'de verilmiştir. Bu mimari içerisindeki her katmanın görevi aşağıdaki gibidir (Jang, 1993):

*Katman 1:* Bu katman girdi değişkenlerine karşılık gelen hücrelerden oluşur. Bu hücrelerin çıktısı, bulanık üyelik değerlerini oluşturmak için aşağıdaki denklemlerle elde edilir:

$$i = 1,2 \text{ için } O_{1,i} = \mu_{A_i}(x); \quad i = 3,4 \text{ için } O_{1,i} = \mu_{B_{i-2}}(y) \quad (13)$$

Burada  $x$  ve  $y$  girdileri;  $A_i$  ve  $B_i$ , girdiler için dilsel etiketleri;  $\mu_{A_i}(x)$  ve  $\mu_{B_i}(y)$  ise üyelik fonksiyonlarıdır. Kullanılabilecek çok farklı üyelik fonksiyonu olsa da genellikle aşağıdaki eşitlikte verilen çan eğrili fonksiyon kullanılır:

$$\mu_{A_i}(x), \mu_{B_{i-2}}(y) = \exp\left(-\frac{x_i - c_i}{a_i}\right)^2 \quad (14)$$

$a_i$  ve  $c_i$ , öncül parametreler olarak adlandırılır.

*Katman 2:* Bu katmandaki her hücre, gelen sinyalleri çarparak aşağıdaki gibi çıktıyı üretir:

$$i = 1,2,3,4 \text{ için } O_{2,i} = w_i = \mu_{A_i}(x) \cdot \mu_{B_{i-2}}(y) \quad (15)$$

Burada  $w_i$ , bir kuralın etki gücüdür.

*Katman 3:* Bu katmandaki her hücre, kendi etki gücünü tüm hücrelerin etki gücüne oranlayarak normalizasyon işlemi gerçekleştirir.

$$i = 1,2,3,4 \text{ için } O_{3,i} = \bar{w}_i = w_i / (w_1 + w_2 + w_3 + w_4) \quad (16)$$


*Katman 4:* Katmandaki  $i$  inci hücre aşağıdaki hücre fonksiyonuna sahiptir:

$$i = 1,2,3,4 \text{ için } O_{4,i} = \bar{w}_i f_i = \bar{w}_i \cdot (p_i x + q_i y + r_i) \quad (17)$$

Burada  $p_i$ ,  $q_i$  ve  $r_i$  ardıl parametreler olarak adlandırılır.

*Katman 5:* Bu katman tek bir hücreden oluşur ve görevi, ağın nihai çıktısını aşağıdaki gibi hesaplamaktır:

$$O_{5,i} = f_{\text{çıkıtı}} = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} = \text{nihai çıktı} \quad (18)$$



Şekil 1. İki girdiye ve dört kurala sahip ANFIS mimarisi.

#### 4.8. Birleştirme (Combining) Yöntemleri

Bates ve Granger (1969) 'ın çalışması, tahmin doğruluğunu arttırmak için farklı modellerin birleştirilmesinden bahseden ilk çalışmadır. Birleştirme tekniklerinin altında yatan düşünce: her modelin desenleri belirleme yöntemi farklıdır ve tekil modellerin tahminlerini birleştirmeye veride bulunan desenlerin daha geniş bir sınıfı tespit edilebilir. Hem teorik hem de deneysel kanıtlar, tahmin doğruluğunun farklı yöntemlerin birleştirilmesiyle artabileceğini göstermiştir

(Newbold & Granger, 1974; Palm & Zellner, 1992; Zhang, 2003; Aras, Nguyen, White & He, 2017). Zou ve Yang (2004) oldukça benzer modellerin birleştirilmesinin de önemli olduğuna ve tek bir modeli seçme zorluğundan kaynaklanan değişkenliğin azaltılmasında birleştirme yöntemlerinin faydasına dikkat çekmiştir. Bir zaman serisini oluşturan sürecin tüm özelliklerini en iyi şekilde modelleyen tek bir tekniğin olmadığı herkesçe kabul edilmiş bir gerçektir (Makridakis vd., 1982). Dolayısıyla tek bir tahmin modeline bağlı kalmak oldukça risklidir. Birleştirme yöntemleri ile yanlış bir tahmin modeli seçmenin riski azaltılmış olacaktır.

Gelişmiş istatistiksel yöntemlere dayalı birçok birleştirme yöntemi olsa da basit yöntemlerle gelişmiş yöntemlere yakın hatta daha iyi tahminler elde edildiği literatürdeki birçok çalışmayla desteklenmiştir (Clemen, 1989; Stock & Watson, 1999; Armstrong, 2001). Basit birleştirme yöntemlerinin: anlaması ve uygulamasının kolay olması, herhangi bir parametre tahminine ihtiyaç duymaması, hatalara daha az maruz kalma eğilimi ve herhangi bir varsayım gerektirmemesi, bu yöntemlerin ilgi çekici özellikleridir. Armstrong (2001), ilgilenilen probleme dair belirsizliğin fazla olması durumunda basit birleştirme yöntemlerinin kullanılmasının iyi bir strateji olacağını belirtmiştir. Basit tahmin metodlarının birbirlerine olan üstünlüğü hakkında kesin bir durum söz konusu değildir (Larrece & Moinpour, 1983; Stock & Watson, 2004; Aras & Gülay, 2017). Bu çalışma kapsamında yararlanılan ve en yaygın olarak kullanılan üç basit birleştirme yöntemi aşağıda verilmiştir:

*Basit Ortalama:* Tekil modellerin  $t$  zamanındaki tüm tahmin değerlerine aynı ağırlık değeri atanır. Çoğu çalışma, bu yöntemin başarılı sonuçlarını rapor etmiştir (Timmermann, 2006; Jose & Winkler, 2008).

*Kırpılmış Ortalama:* En yüksek ve en düşük tahminlerin bir kısmının atılması ardından, hesaplanan ortalamadır. %20 'lik kırpma miktarının faydasının literatürde incelendiği görülmüştür (Jose & Winkler, 2008; Wilcox, 2012).

*Medyan:* Tekil modeller tarafından oluşturulan tahminlerin medyanı, nihai tahmin olarak kullanılır. Medyan birleştirmesi basit ortalama birleştirme tekniğine göre uç değerlerden daha az etkilenmesi nedeniyle iyi sonuçlar üretme eğiliminde olduğu iddia edilmiştir (Stock & Watson, 2004; Wallis, 2011).

## 5. DENEYSEL SONUÇLAR

### 5.1 Veri Setleri ve Model Parametreleri


Çalışmada incelenen veri setlerine Coinmarketcap (2018) adresinden erişim sağlanmış ve günlük kapanış fiyat verileri elde edilmiştir. Bitcoin için 28

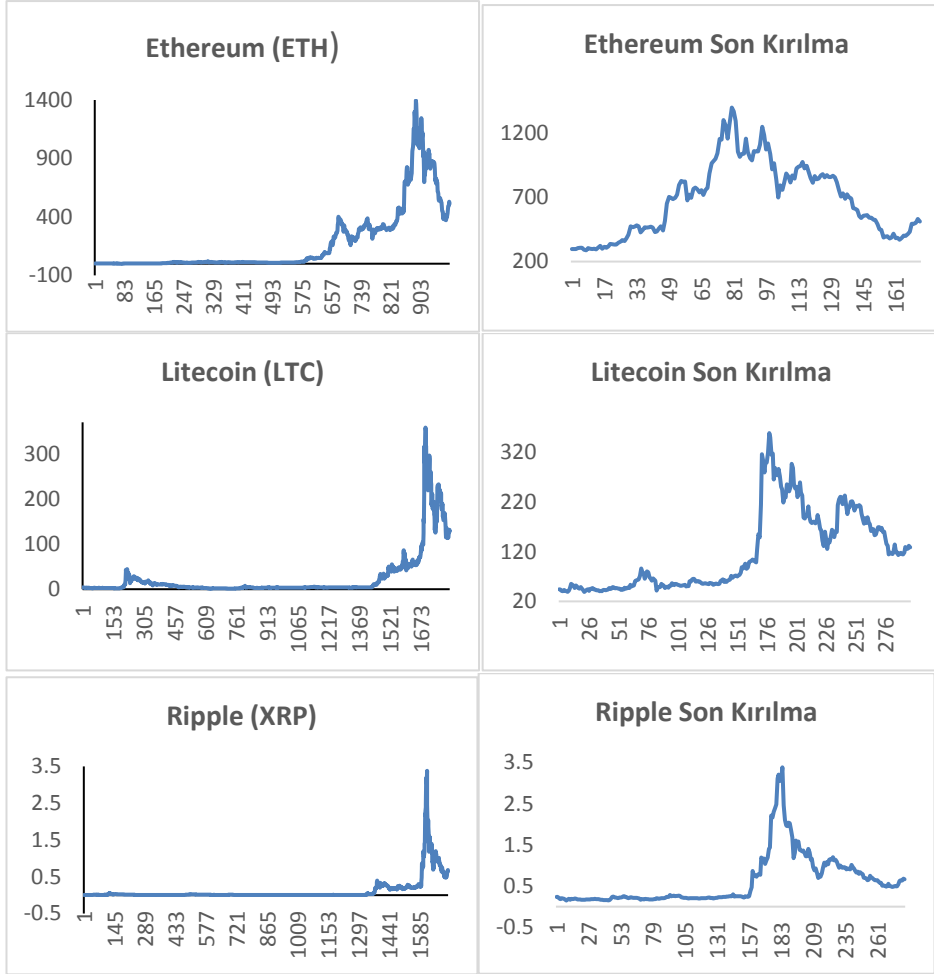


Nisan 2013, Ethereum için 7 Ağustos 2015, Litecoin için 28 Nisan 2013, Ripple için ise 4 Ağustos 2013 tarihinden itibaren günlük veriler kullanılmıştır. Verilerin indirildiği 15 Nisan 2018 tarihi son veri olarak alınmıştır. Bu verilere ait zaman yolu grafikleri Şekil 2 'de verilmiştir. Şekil 2 'de görüleceği üzere bu para birimlerinin hepsinde son dönemde yüksek oynaklık gözlenmektedir. Bu gözlemin ardından, her bir veri seti için durağanlık testleri (Augmented Dickey-Fuller ve KPSS testi) yapılmış ve her iki test sonucunda, tüm veri setlerinin durağan olmadığı tespit edilmiştir. Serilerin farkları alınarak durağan hale getirilmiş ve analize farkı alınmış seriler üzerinden devam edilmiştir.

Ayrıca serilerde son dönemde gözlenen aşırı oynaklık, bu seriler için yapısal kırılma test sonuçlarını göz önünde bulunduramıza yol açmıştır. Bu amaçla çoklu yapısal kırılma testlerine başvurulmuş ve son kırılmadan itibaren bahsi geçen zaman serisi modellerinin tekrar oluşturulmasına karar verilmiştir. Çoklu yapısal değişim modellerini oluşturmada Eviews programı kullanılmıştır. Varsayılan olarak, testler maksimum beş kırılma sayısına izin vermekte, %15 'lik bir kırılma yüzdesi kullanmakta ve ardışık test için 0,05 'lik anlam düzeyine bakmaktadır. Bununla birlikte, kırılmalar boyunca heterojen hata dağılımlarına izin verilmiştir.

Tüm veri setlerinde son 30 gözlem, tahmin performansını objektif bir şekilde değerlendirmek amacıyla test seti olarak alınmıştır. Her bir veri setinde test setinden önce gelen yine 30 veri, model parametrelerine karar vermek ve eğitimi durdurmak için doğrulama seti olarak kullanılmıştır. Geriye kalan verilerden ise eğitim seti olarak parametrelerin tahmininde faydalanılmıştır. Bir adım ileri (one-step ahead) tahminler üretilmiştir. Her bir nokta tahmininin ardından, tahmin edilen gerçek değer sonraki bir adımlık tahmini üretirken oluşturulacak yeni modelin parametrelerinin belirlenmesi amacıyla modele dahil edilmiştir. Son veri noktasının tahminine kadar iteratif olarak bu işlemlere devam edilmiştir.





**Şekil 2.** İncelenen Kripto Paralara Ait Zaman Yolu Grafikleri.

Bu çalışmanın başlıca odak noktası, örnek dışında kripto para fiyatlarının tahmin edilmesidir. Test setinde elde edilen tahmin doğruluğu, en önemli performans ölçüsüdür. Örnek dışı performansı ölçmek için kullanılan değerlendirme ölçülerinden hangisinin en iyi hata ölçüsü olduğu hakkında kesin bir bilgi bulunmamaktadır (Makridakis vd., 1982). Bu sebepten ötürü, aşağıdaki değerlendirme ölçüleri bu çalışma kapsamında kullanılmıştır:

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (\hat{y}_t - y_t)^2}{n}} \quad (19)$$

$$MAE = \frac{1}{n} \sum_{t=1}^n |\hat{y}_t - y_t| \quad (20)$$

$$MAPE = \frac{100\%}{n} \sum_{t=1}^n \left| \frac{y_t - \hat{y}_t}{y_t} \right| \quad (21)$$

$$\text{Theil-U} = \sqrt{\frac{\sum_{t=1}^n (\hat{y}_{t+1} - y_{t+1})^2}{\sum_{t=1}^n \left( \frac{y_{t+1} - y_t}{y_t} \right)^2}} \quad (22)$$

$$D_{stat} = \frac{1}{N} \sum_{k=1}^N a_k \quad (23)$$

$D_{stat}$  ölçüsünde, eğer  $(y_{t+1} - y_t)(\hat{y}_{t+1} - y_t) > 0$  ise  $a_k = 1$ , diğer durumlarda  $a_k = 0$  değerini alır.  $t$  zamanındaki gözlemi  $y_t$  ve  $t$  zamanındaki tahmin değerini ise  $\hat{y}_t$  göstermektedir.

RMSE ve MAE sıklıkla kullanılan ölçüğe bağlı ölçülerdir. MAPE ise ölçüğe bağlı olmadığından, farklı veri setleri üzerinde tahmin performansının karşılaştırma avantajına sahiptir. Ancak gözlem değerinin sıfır veya sıfıra yakın olması durumunda, sonsuz veya büyük değerler üretme riski taşımaktadır. Theil-U istatistiği, ele alınan model ile rassal yürüyüş arasında karşılaştırma yapma imkanı sağlamaktadır. Eğer bu istatistik 1 değerine eşitse rassal yürüyüşten farksız, 1 'den büyük ise rassal yürüyüşten kötü ve 1 'den küçük ise incelenen modelin rassal yürüyüşten daha iyi olduğu anlaşılır. Bahsi geçen ölçüler, dönüm noktalarının ölçülmesini ihmal etmektedir. Aslında yön tahminleri, alım-satım kararlarının belirlenmesinde çok önemli rol oynamaktadır. Yao ve Tan (2000), yön değişim istatistiğini değerlendirmek için  $D_{stat}$  yön doğruluğu istatistiğini önermişlerdir. Böylece modelin trendindeki değişim doğrudan incelenebilir.

Son olarak çalışma kapsamında elde edilen sonuçlara geçmeden önce, yararlanılan modellerin parametrelerinden bahsedilecektir. Üstel düzeltme için oluşturulan durum uzay modellerine ilişkin sağlanan istatistiksel çerçeve, herkesçe bilinen bilgi kriterlerinin model seçiminde faydalanılmasına imkan vermektedir. Bu çalışmada, olası 30 ETS modeli arasından hangi modelin seçileceğinin belirlenmesi amacıyla yönelik olarak düzeltilmiş AIC bilgi kriterinden faydalanılmıştır. Çalışmadaki ARIMA modelleri oluşturulurken, Hyndman ve Khandakar (2007) tarafından önerilen otomatik ARIMA modeli oluşturma algoritmasından faydalanılmıştır. Bu algoritma, tekrarlı KPSS testlerini kullanarak fark alınma sayısını belirler. Ardından düzeltilmiş AIC minimizasyonuna bakarak,  $p$  ve  $q$  değerlerini seçer. Tüm olası  $p$  ve  $q$  kombinasyonları yerine, algoritma model uzayında adım adım arama yapar. Algoritmaya ilişkin daha fazla detay Hyndman ve Khandakar (2007) tarafından sağlanmıştır. R programlama dilinin *forecast* paketinde bulunan *ets* fonksiyonu

olası ETS modellerini kurmak ve yine aynı paketteki *auto.arima* fonksiyonu çalışmadaki ARIMA modellerini oluşturmak için kullanılmıştır.

MLP modelleri oluşturulurken girdi hücre sayısına 1 ‘den 10 ‘a kadar, gizli hücre sayısına ise 1 ‘den 5 ‘e kadar izin verilmiştir. Her bir girdi-gizli hücre kombinasyonu 30 farklı başlangıç ağırlık değeriyle tekrarlanmıştır. Böylece toplamda her bir seri için 1500 sinir ağı modeli oluşturulmuştur. Ardından her girdi hücresine karşılık gelen farklı sayıdaki gizli hücre kombinasyonlarında 30 farklı sinir ağı olduğundan, bu ağların doğrulama seti üzerindeki karesel hataları üzerinde alt ve üstten %20 ‘lik olmak üzere kırılmış ortalama değerleri hesaplanmıştır. Böylece, her bir girdi hücre için 5 tane kırılmış ortalama değeri elde edilmiştir. Bu kırılmış ortalamaların da ortalaması bulunarak, en küçük değeri veren girdi hücre sayısı yapay sinir ağının nihai gecikme sayısını vermiştir. Gizli hücre sayısı ise, belirlenen girdi hücre sayısına karşılık gelen farklı sayıdaki gizli hücrelere ait 5 tane kırılmış ortalamadan en küçüğü alınarak belirlenmiştir. Ayrıca en çok kullanılan ve popüler olan geri yayılım algoritması, sinir ağı modellerinin oluşturulmasında kullanılmış ve Levenberg-Marquardt optimizasyon algoritmasından faydalanılmıştır. Girdi katmanında aktivasyon fonksiyonu kullanılmamış, gizli katmanda lojistik fonksiyon ve bir adım ileri tahminler üretildiği için tek hücreden oluşan çıktı katmanında ise doğrusal fonksiyon kullanılmıştır.

ANFIS modellerine ait Sugeno tipindeki başlangıç bulanık çıkarım sistemi için, bulanık c-ortalamalar kümeleme tekniği ile bulunan kümeler aracılığıyla kurallar türetilmiştir. Girdi hücreleri için gaussian üyelik fonksiyonu ve çıktı hücresi için doğrusal üyelik fonksiyonu kullanılmıştır. Küme ve gecikme sayısına doğrulama seti üzerindeki hata performansına bakılarak karar verilmiştir. Bulanık ayrışım matrisinin üs değeri 2 olarak alınmıştır. Maksimum eğitim devir sayısı 100 olarak ayarlanmıştır. Eğitim algoritması olarak, melez yöntem seçilmiştir. Bu yöntem girdi üyelik fonksiyonunun parametrelerini hesaplamak için geriye yayılım algoritmasını kullanırken, çıktı üyelik fonksiyonunun parametrelerini hesaplamak için ise en küçük kareler yöntemini kullanmaktadır.

LS-SVM modelleri oluşturulurken kullanılacak gecikme sayısı MLP modellerinde belirlenen gecikme sayısı ile aynı olarak alınmıştır. Radyal tabanlı fonksiyon, çalışmada çekirdek fonksiyon olarak alınmıştır.  $\sigma^2$  ve  $\gamma$  parametrelerini belirlemek amacıyla 10 hacimli çapraz doğrulama setleri üzerindeki karesel hata baz alınarak ızgara sisteminden yararlanılmıştır. MLP, ANFIS ve LS-SVM modellerinin tümü MATLAB paket programında oluşturulmuştur.

Tablo 3, her bir veri seti için oluşturulan üç farklı yapay sinir ağına ait belirlenen parametre değerlerini özetlemektedir. MLP ve ANFIS için kullanılan  $(G \times S \times \zeta)$  ve  $(G \times K \times \zeta)$  gösteriminde sırasıyla:  $G$ , gecikme sayısını;  $S$ , gizli hücre sayısını;  $K$ , ANFIS modelinde kullanılan küme sayısını;  $\zeta$  ise çıktı hücre sayısını göstermektedir.

**Tablo 3.** İncelenen Veri Setleri İçin Oluşturulan Yapay Sinir Ağı Türlerine Ait Kullanılan Parametreler.

Veri Setleri	Parametreler	MLP	ANFIS	LS-SVM	
				$\gamma$	$\sigma^2$
<b>Bitcoin</b>	Son Kırılma	1×5×1	1×2×1	0,187	0,00017
	Son 2 Yıl	1×5×1	1×2×1	0,049	0,00131
	Tüm Veriler	1×3×1	1×3×1	0,026	0,00381
<b>Ethereum</b>	Son Kırılma	1×1×1	1×2×1	78,46	10730,4
	Son 2 Yıl	2×3×1	1×3×1	6,85e-09	367863,1
	Tüm Veriler	2×1×1	1×3×1	1,72e-08	640660,1
<b>Litecoin</b>	Son Kırılma	1×2×1	1×2×1	0,302	1,29e-06
	Son 2 Yıl	1×2×1	2×3×1	644,9	1,969
	Tüm Veriler	1×2×1	1×3×1	0,662	0,00279
<b>Ripple</b>	Son Kırılma	3×5×1	3×2×1	0,162	0,387
	Son 2 Yıl	3×3×1	1×2×1	0,196	1,177
	Tüm Veriler	3×5×1	1×3×1	0,212	2,895

## 5.2 Elde Edilen Bulgular

Öncelikle Bitcoin, Ethereum, Litecoin ve Ripple serileri için yapılan çoklu kırılma test sonuçları Tablo 4-7 arasında verilmiştir. Bu tablolardan görüleceği üzere, ele alınan her iki bilgi kriteri de Bitcoin ve Ethereum için 2 kırılma tespit etmiş, ancak Litecoin ve Ripple serileri için ise tek kırılmanın var olduğu sonucuna varmıştır. Kırılmalara ait açık tarihler tabloların altında verilmiş ve seçilen kırılma sayıları tablolarda arka planı gölgelendirilerek belirtilmiştir. Dört veri setinde de tespit edilen ortak gözlem, bu serilerin 2017 yılının ikinci yarısı itibariyle yapısal bir değişim yaşadığıdır. Bu tarihler itibariyle incelenen serilerde oynaklığın arttığı ve yukarı doğru bir trend eğilimi olduğu gözlemlenmiştir. Elde edilen bu bulgular ışığında, veri setleri sadece son kırılma sonrası verileri içerecek şekilde, son iki yılı içerecek şekilde ve son olarak, tüm veri tarihini içerecek şekilde oluşturularak daha önce bahsi geçen tahmin tekniklerinin uygulanması yoluna gidilmiştir.

Tablo 8 'de Bitcoin ve Ethereum serileri için ele alınan tüm veri aralığı, son iki yıl ve son kırılma tarihinden itibaren alınan verilerle oluşturulan modellere ilişkin test seti üzerindeki çeşitli tahmin performans istatistikleri sunulmuştur. Tahmin değerlendirme ölçülerinden her biri tahminin farklı özelliğini

değerlendirmektedir ve bu ölçüler arasında herhangi bir üstünlük bulunmamaktadır. Bu tablodan anlaşılacağı üzere, Bitcoin serisi için son kırılma verileriyle en iyi dört hata performans ölçüsüne LS-SVM modeliyle ulaşılmıştır. Ancak yön doğruluğu istatistiği açısından değerlendirildiğinde, ARIMA modeli ve Medyan birleştirme yöntemi daha yüksek hata değerlerine karşın daha doğru bir şekilde serideki dönüm noktalarını belirlemişler ve yaklaşık %67 'lik bir yön doğruluk tahminine ulaşmışlardır. Yatırımcılar açısından bakıldığında, birçok yatırımcı alım-satım kararlarında yardım sağlaması açısından trendi kullanmaktadır. Burada altta yatan düşünce, bir trend başlarsa bunun devam edeceği varsayımdır. Yatırımcı trendi takip ederek, trendde erkenden pozisyon almak ve trend devam ettiği sürece de pozisyonunu korumak ister. Ancak, trendde bir değişim tahmin edildiğinde ise pozisyonunu değiştirmek isteyebilir. Bu açıdan, tahminin gerçek amacı tahmin sonuçlarına dayanarak kar elde etmektir. Dolayısıyla %67 'lik bir yön doğruluğu yatırımcılar için cezbedici olacaktır. Bitcoin verisi için veri seti hacminin artırılarak son iki yıl veya tüm veri seti yapılmasının, ilk dört hata ölçüsünün değerlerini küçük miktarda iyileştirdiği görülmüştür. Bununla birlikte, yön doğruluğunda bir iyileşme gerçekleşme yerine bir düşüş yaşanmıştır. Dolayısıyla Bitcoin serisi için son kırılmaya ait verilerin, yatırımcılar için daha çok kar potansiyeli içerdiği söylenebilir. Ayrıca Bitcoin serisine ait yapılan farklı veri hacmine dayanan modellerin tümünde, Theil-U istatistiğinin gösterdiği gibi, ETS modeli hariç, rassal yürüyüş modelinden daha iyi sonuçlar elde edilmiştir. Bu sonuç, modellemeden fayda sağlandığını işaret etmektedir. Aynı analiz yorumlarını, Ethereum serisi için yapmak mümkün değildir. Bu seri tüm farklı veri hacimlerinde rassal yürüyüşü birkaç özel durum hariç nerdeyse geçememiştir. Yön doğruluğu, tüm verilerin ve birleştirme yöntemlerinden kırılmış ortalama yönteminin kullanıldığı durum hariç, neredeyse hep %50 civarında kalarak faydasız bir görünüm sergilemiştir.

**Tablo 4.** Bitcoin İçin Yapılan Çoklu Kırılma Testi Sonucu.

Schwarz kriterine göre seçilen kırılmalar					
LWZ kriterine göre seçilen kırılmalar					
Kırılmalar	Katsayı Sayısı	Karesel Artık Toplamı	Log-L	Schwarz* Kriteri	LWZ* Kriteri
0	1	1,71E+10	-16873,05	16,08230	16,09015
1	3	5,62E+09	-15878,87	14,97614	14,99970
2	5	5,49E+09	-15857,13	14,96016	14,99943
3	7	5,48E+09	-15856,36	14,96769	15,02267
4	9	5,48E+09	-15855,46	14,97507	15,04576
5	11	5,47E+09	-15854,11	14,98195	15,06835

\*Minimum bilgi kriteri değeri gölgelendirilerek gösterilmiştir.

Tahmin edilen kırılma tarihleri:

1: 23 Haziran 2017

2: 29 Eylül 2016, 23 Haziran 2017

3: 11 Aralık 2015, 29 Eylül 2016, 23 Haziran 2017

4: 16 Aralık 2014, 11 Aralık 2015, 29 Eylül 2016, 23 Haziran 2017

5: 20 Ocak 2014, 14 Ekim 2014, 7 Aralık 2015, 29 Eylül 2016, 23 Haziran 2017

**Tablo 5.** Ethereum İçin Yapılan Çoklu Kırılma Testi Sonucu.

Kırılmalar	Katsayı Sayısı	Karesel Artık Toplamı	Log-L	Schwarz* Kriteri	LWZ* Kriteri
0	1	74487238	-6727,299	11,27267	11,28441
1	3	21746093	-6140,019	10,05586	10,09109
2	5	12726078	-5884,452	9,534458	9,593181
3	7	12632652	-5880,937	9,541472	9,623692
4	9	12621290	-5880,508	9,554955	9,660677
5	11	12621246	-5880,506	9,569335	9,698562

\*Minimum bilgi kriteri değeri gölgelendirilerek gösterilmiştir.

Tahmin edilen kırılma tarihleri:

1: 26 Ekim 2017

2: 21 Mayıs 2017, 26 Ekim 2017

3: 30 Aralık 2016, 21 Mayıs 2017, 26 Ekim 2017

4: 30 Aralık 2016, 21 Mayıs 2017, 26 Ekim 2017

5: 1 Mart 2016, 1 Ağustos 2016, 30 Aralık 2016, 21 Mayıs 2017, 26 Ekim 2017

**Tablo 6.** Litecoin İçin Yapılan Çoklu Kırılma Testi Sonucu.

Kırılmalar	Katsayı Sayısı	Karesel Artık Toplamı	Log-L	Schwarz* Kriteri	LWZ* Kriteri
0	1	4666660	-9555,692	7,872975	7,880825
1	3	1946352	-8775,213	7,006877	7,030429
2	5	1938618	-8771,659	7,011285	7,050538
3	7	1929441	-8767,424	7,014928	7,069886
4	9	1929300	-8767,359	7,023244	7,093906
5	11	1929597	-8767,496	7,031788	7,118156

\*Minimum bilgi kriteri değeri gölgelendirilerek gösterilmiştir.

Tahmin edilen kırılma tarihleri:

1: 24 Haziran 2017

- 2: 4 Ağustos 2014, 24 Haziran 2017  
 3: 11 Ağustos 2014, 30 Eylül 2016, 24 Haziran 2017  
 4: 11 Ağustos 2014, 28 Haziran 2015, 30 Eylül 2016, 24 Haziran 2017  
 5: 20 Ocak 2014, 14 Ekim 2014, 8 Temmuz 2015, 30 Eylül 2016, 24 Haziran 2017

**Tablo 7.** Ripple İçin Yapılan Çoklu Kırılma Testi Sonucu.

Schwarz kriterine göre seçilen kırılmalar					
					1
LWZ kriterine göre seçilen kırılmalar					
					1
Kırılmalar	Katsayı Sayısı	Karesel Artık Toplamı	Log-L	Schwarz* Kriteri	LWZ* Kriteri
0	1	185,7318	-532,6482	-2,201999	-2,193851
1	3	110,3570	-93,53613	-2,713773	-2,689328
2	5	109,4026	-86,20945	-2,713649	-2,672906
3	7	109,3929	-86,13485	-2,704928	-2,647885
4	9	109,3919	-86,12703	-2,696128	-2,622784
5	11	109,3893	-86,10703	-2,687342	-2,597696

\*Minimum bilgi kriteri değeri gölgelendirilerek gösterilmiştir.

Tahmin edilen kırılma tarihleri:

- 1: 8 Temmuz 2017  
 2: 28 Ekim 2016, 8 Temmuz 2017  
 3: 14 Nisan 2014, 28 Ekim 2016, 8 Temmuz 2017  
 4: 14 Nisan 2014, 16 Eylül 2015, 28 Ekim 2016, 8 Temmuz 2017  
 5: 14 Nisan 2014, 23 Aralık 2014, 2 Eylül 2015, 28 Ekim 2016, 8 Temmuz 2017

**Tablo 8.** Bitcoin ve Ethereum Kripto Paralarına Ait Test Seti Üzerinde Yararlanılan Tahmin Yöntemleriyle Elde Edilen Tahmin Performans İstatistikleri.

Teknikler	Bitcoin					Ethereum				
	RMSE	MAE	MAPE	Theil-U	D <sub>stat</sub>	RMSE	MAE	MAPE	Theil-U	D <sub>stat</sub>
Rassal Yürüyüş	334,4	262,0	3,44	1,000	-	23,62	17,20	3,86	1,000	-
Yönlü Rassal Yür.	335,6	261,4	3,43	0,999	0,567	23,83	17,44	3,91	1,004	0,500
AR (1)	333,6	262,5	3,44	0,998	0,533	<b>23,55</b>	17,47	3,94	1,001	<b>0,533</b>
ETS	334,4	262,0	3,44	1,000	-	23,62	<b>17,20</b>	<b>3,86</b>	1,000	-
ARIMA	330,7	256,2	3,36	0,989	<b>0,667</b>	23,62	17,20	3,86	1,000	-
MLP	332,1	255,0	3,34	0,984	0,600	23,90	17,71	3,96	1,013	0,433
ANFIS	334,2	260,7	3,42	0,992	0,533	24,23	17,88	4,02	1,015	0,500
LS-SVM	<b>318,4</b>	<b>252,7</b>	<b>3,32</b>	<b>0,944</b>	0,600	23,79	17,29	3,88	1,001	0,500
Basit Ort.	330,0	257,3	3,37	0,982	0,633	23,68	17,28	3,88	1,000	0,467
Kırılmış Ort.	331,7	258,6	3,39	0,988	0,533	23,71	17,33	3,89	1,002	0,467
Medyan	331,5	257,3	3,37	0,989	<b>0,667</b>	23,65	17,31	3,89	<b>1,000</b>	0,500



Teknikler	Bitcoin					Ethereum				
	RMSE	MAE	MAPE	Theil-U	Son Kırılma					
					D <sub>stat</sub>	RMSE	MAE	MAPE	Theil-U	D <sub>stat</sub>
Son 2 Yıl										
Rassal Yürüyüş	334,4	262,0	3,44	1,000	-	23,62	<b>17,20</b>	<b>3,86</b>	1,000	-
Yönlü Rassal Yür.	334,8	261,1	3,43	0,999	0,567	23,69	17,25	3,87	1,000	0,500
AR (1)	333,5	262,4	3,44	0,997	0,533	23,56	17,48	3,94	1,002	0,533
ETS	334,4	262,0	3,44	1,000	-	24,45	18,32	4,15	1,049	0,367
ARIMA	328,1	253,5	3,32	0,982	0,600	24,44	17,92	3,99	1,031	0,533
MLP	330,0	<b>249,9</b>	<b>3,27</b>	0,982	<b>0,633</b>	23,61	17,89	4,02	1,014	0,500
ANFIS	333,7	261,5	3,43	0,995	0,500	23,58	17,39	3,92	0,998	<b>0,567</b>
LS-SVM	<b>323,1</b>	250,1	3,28	<b>0,959</b>	0,600	<b>23,42</b>	17,29	3,90	<b>0,991</b>	0,600
Basit Ort.	329,6	256,1	3,36	0,983	<b>0,633</b>	23,69	17,51	3,94	1,006	0,500
Kırılmış Ort.	330,6	257,2	3,37	0,986	0,600	23,66	17,48	3,93	1,004	0,467
Medyan	331,3	257,8	3,38	0,989	0,600	23,64	17,48	3,93	1,002	0,500
Tüm Veriler										
Rassal Yürüyüş	334,4	262,0	3,44	1,000	-	23,62	<b>17,20</b>	<b>3,86</b>	1,000	-
Yönlü Rassal Yür.	334,5	261,5	3,43	0,999	0,567	23,67	17,23	3,87	1,000	0,500
AR (1)	333,6	262,5	3,44	0,998	0,533	23,56	17,44	3,93	1,001	0,533
ETS	334,7	262,8	3,45	1,001	0,467	24,27	19,38	4,35	1,062	0,500
ARIMA	328,3	253,4	3,32	0,983	0,600	24,25	17,46	3,88	1,022	0,567
MLP	333,8	263,4	3,46	0,999	0,533	23,54	17,50	3,93	1,006	0,500
ANFIS	333,5	261,8	3,44	0,996	0,500	23,63	17,48	3,93	0,999	0,533
LS-SVM	<b>318,0</b>	<b>250,9</b>	<b>3,29</b>	<b>0,942</b>	0,600	23,62	17,21	3,87	0,998	0,533
Basit Ort.	329,2	257,1	3,37	0,983	<b>0,633</b>	<b>23,49</b>	17,34	3,90	1,000	0,533
Kırılmış Ort.	330,9	258,2	3,39	0,988	0,567	23,64	17,36	3,90	1,004	<b>0,633</b>
Medyan	330,7	258,7	3,39	0,989	<b>0,633</b>	23,53	17,35	3,90	<b>0,998</b>	0,533

Not: Tablo içerisindeki koyu renkler, her bir veri seti için oluşturulan tahmin modelleri arasında ilgili hata ölçüsüne göre elde edilen en iyi değeri göstermek için kullanılmıştır.

Tablo 9, Litecoin ve Ripple kripto paraları ile yapılan modelleme sonucunda elde edilen tahminlerin performans istatistiklerini sunmaktadır. Hemen belirtilmelidir ki, söz konusu tablolarda bazı ETS ve ARIMA modellerinin yön istatistikleri bulunmamaktadır. Bunun nedeni, ETS ve ARIMA modelleme prosedürlerinin ilgili durumlarda model aday havuzundan rassal yürüyüş modelini seçmiş olmasıdır. Ayrıca tablolardan görüleceği üzere, bu durum gerçekleşmesi halinde birleştirme yöntemlerinin yön istatistikleri %50 'nin altına inmiştir. Litecoin için son iki yıla ait verilerle yapılan modellemede, ANFIS modelinin mutlak bir üstünlüğü söz konusudur. Yön doğruluğunun %60 'a kadar çıktığı görülmektedir. Son kırılmaya ait veriler için de yine ANFIS modeliyle iyi bir yön doğruluğu yakalanmış olsa da, tüm verilerin kullanıldığı modellemeler anlamlı bir avantaj üstünlüğü sağlamamaktadır. Theil-U istatistiği de bu sonucu destekler niteliktedir. Son kırılma ve iki yıllık veri setlerinde,

özellikle birleştirme yöntemleriyle 1 'in altında değerlere ulaşılmıştır. Ancak, elde edilen sonuçlar 1 değerine oldukça yakındır. Dolayısıyla rassal yürüyüş modelinin anlamlı seviyede geçildiği söylenemez. Litecoin için çıkarılabilecek tek anlamlı sonuç, son kırılma ve iki yıllık veriler üzerinde ANFIS modeliyle anlamlı bir yön doğruluğuna ulaşılmış olduğudur. Ripple kripto parası ile yapılan analiz için de benzer sonuçlara ulaşılmıştır. Son kırılma ve iki yıllık veri setinde ANFIS modeliyle anlamlı olabilecek sonuçlar elde edilmiştir. Diğer tüm modelleme tekniklerinin ve eldeki mevcut veri setinin hepsinin kullanılmasının işe yarar tahminlere yol açmadığı görülmüştür.

## 6. SONUÇ

Yasal parayla sanal para arasındaki farklılık merkezi olmamasında yatmaktadır. Bunun anlamı, sanal paranın önümüzdeki gün bile değersiz olmayacağını bir garantisinin olmamasıdır. Bu sebeple, bu sanal paraların fiyatlarının nasıl değiştiğini anlamak önem arz etmektedir. Ayrıca, kripto paraların fiyatlarının zaman içerisindeki yüksek dalgalanması spekülasyon için cazip olmuştur. 2017 yılı Bitcoin için ani yükseliş yılı olmuştur. 2016 yılının başına göre 2017 'nin ilk yıllarında dolar cinsinden değeri iki katına çıkmış ve 2017 'nin ortalarında fiyatı yine iki katına çıkmıştır. Ancak 2018 yılında Bitcoin fiyatında ciddi düşüşler gözlemlenmiştir. Bu çalışmanın ana unsuru, sanal para fiyatlarının tahmin edilebilirliğini farklı tür modelleme yeteneğine sahip tekniklerle incelemektir. Çalışmada temel analiz yerine teknik analiz kullanılmıştır. Çünkü kripto para fiyatlarının hangi değişkenlerle ne tür bir ilişki içinde olduğu konusunda belirsizlik vardır. Dolayısıyla verinin kendi iç dinamiklerinden faydalanarak tahmin yapılmaya çalışılmıştır. Tek bir tahmin

**Tablo 9.** Litecoin ve Ripple Kripto Paralarına Ait Test Seti Üzerinde Yararlanılan Tahmin Yöntemleriyle Elde Edilen Tahmin Performans İstatistikleri.

Teknikler	Litecoin					Ripple					
	MSE	MAE	MAPE	Theil-U	Son Kırılma		RMSE	MAE	MAPE	TheilU	D <sub>stat</sub>
					D <sub>stat</sub>	D <sub>stat</sub>					
Rassal Yürüyüş	7,33	5,55	4,21	1,000	-	0,0365	0,0264	4,46	1,000	-	-
Yönlü Rassal Yür.	7,39	5,54	4,22	1,005	0,533	0,0365	0,0268	4,52	1,000	0,467	0,467
AR (1)	7,38	5,71	4,35	1,008	0,400	0,0365	<b>0,0263</b>	<b>4,46</b>	0,996	0,467	0,467
ETS	7,33	5,55	4,21	1,000	-	0,0365	0,0264	4,46	1,000	-	-
ARIMA	7,33	5,55	4,21	1,000	-	0,0365	0,0264	4,46	1,000	-	-
MLP	7,29	5,55	<b>4,20</b>	1,001	0,467	0,0367	0,0274	4,62	1,011	0,433	0,433
ANFIS	7,48	5,56	4,23	1,019	<b>0,567</b>	0,0364	0,0277	4,69	<b>0,987</b>	<b>0,567</b>	<b>0,567</b>
LS-SVM	<b>7,28</b>	5,94	4,48	<b>0,985</b>	0,467	0,0388	0,0312	5,28	1,037	0,467	0,467
Basit Ort.	7,32	5,61	4,26	0,998	0,367	<b>0,0363</b>	0,0270	4,56	0,991	0,467	0,467
Kırılmış Ort.	7,33	5,57	4,24	0,999	0,467	0,0363	0,0268	4,54	0,992	0,433	0,433
Medyan	7,32	<b>5,54</b>	4,21	0,998	0,200	0,0365	0,0266	4,50	0,997	0,433	0,433

Litecoin					Ripple					
Teknikler	MSE	MAE	MAPE	Theil-U	Son Kırılma		MAE	MAPE	TheilU	D <sub>stat</sub>
					D <sub>stat</sub>	RMSE				
Son 2 Yıl										
Rassal Yürüyüş	7,33	5,55	4,21	1,000	-	0,0365	0,0264	4,46	1,000	-
Yönlü Rassal Yür.	7,36	5,53	4,21	1,002	0,533	0,0365	0,0266	4,49	1,000	0,467
AR (1)	7,38	5,71	4,35	1,008	0,400	0,0365	<b>0,0263</b>	<b>4,45</b>	0,996	0,467
ETS	7,33	5,55	4,21	1,000	-	0,0410	0,0332	5,58	1,091	0,433
ARIMA	7,33	5,55	4,21	1,000	-	0,0380	0,0289	4,92	1,050	0,433
MLP	7,34	5,53	4,20	1,000	0,533	0,0371	0,0270	4,56	1,025	0,500
ANFIS	<b>7,24</b>	<b>5,45</b>	<b>4,12</b>	<b>0,970</b>	<b>0,600</b>	0,0363	0,0270	4,60	<b>0,984</b>	<b>0,567</b>
LS-SVM	7,67	6,30	4,73	1,033	0,433	0,0383	0,0307	5,19	1,030	0,433
Basit Ort.	7,30	5,58	4,24	0,993	0,467	0,0367	0,0276	4,68	1,000	0,433
Kırılmış Ort.	7,33	5,55	4,22	0,998	0,433	0,0365	0,0273	4,63	0,995	0,467
Medyan	7,33	5,54	4,21	0,998	0,500	<b>0,0363</b>	0,0269	4,56	0,988	0,500
Tüm Veriler										
Rassal Yürüyüş	7,33	5,55	4,21	1,000	-	0,0365	0,0264	4,46	1,000	-
Yönlü Rassal Yür.	7,34	5,54	4,21	1,001	0,533	0,0365	0,0264	4,47	1,000	0,467
AR (1)	7,39	5,72	4,35	1,008	0,400	0,0365	<b>0,0263</b>	<b>4,46</b>	0,996	0,467
ETS	7,40	5,76	4,35	1,022	0,467	0,0382	0,0282	4,78	1,047	<b>0,533</b>
ARIMA	7,57	5,82	4,43	1,031	0,400	0,0380	0,0289	4,91	1,050	0,433
MLP	7,30	<b>5,53</b>	<b>4,19</b>	1,000	<b>0,500</b>	0,0371	0,0277	4,66	1,023	0,467
ANFIS	7,42	5,74	4,37	1,011	0,433	0,0371	0,0270	4,55	1,008	0,500
LS-SVM	<b>7,29</b>	5,81	4,41	<b>0,992</b>	0,467	0,0380	0,0299	5,05	1,025	0,467
Basit Ort.	7,35	5,67	4,31	1,004	0,367	0,0366	0,0271	4,58	1,003	0,467
Kırılmış Ort.	7,33	5,66	4,30	1,002	0,433	0,0363	0,0268	4,54	0,996	0,467
Medyan	7,30	5,65	4,30	0,996	0,400	<b>0,0362</b>	0,0265	4,47	<b>0,990</b>	0,500

*Not:* Tablo içerisindeki koyu renkler, her bir veri seti için oluşturulan tahmin modelleri arasında ilgili hata ölçüsüne göre elde edilen en iyi değeri göstermek için kullanılmıştır.

yöntemi kullanmakla farklı kripto para fiyatlarında aynı performansı elde etmek pek olası değildir. Bu sebeple, birkaç tahmin yönteminin birleştirilmesi hem tek bir tahmin tekniğini seçmeden kaynaklanacak riski azaltacak hem de daha iyi sonuçlara ulaşmamızı sağlamıştır.

Bu çalışmada, kripto paralar kapsamlı bir analize tabi tutulmuştur. Bu amaçla, öncelikle kripto para çeşitleri ve fiyatlandırma detaylı bir şekilde açıklanarak anlatılmıştır. Modelleme aşamasında, kripto para birimlerinin fiyatları; yönlü rassal yürüyüş, AR(1), ETS, ARIMA, MLP, ANFIS ve LS-SVM modelleri ile tahmin edilmiştir. Ayrıca basit birleştirme tekniklerinden faydalanılmıştır. Analiz sonucunda, Bitcoin kripto parasına yönelik modelleme çalışması baz alınan 4 kripto para içerisinden en iyi sonuçları vermiştir. Özellikle son kırılma ve son iki yıla ait verilerle yön doğruluğunda %67 oranında bir başarı elde edilmiştir. LS-SVM modelinin bu veri seti üzerindeki üstünlüğü daha açıktır.

Ayrıca birleştirme yöntemleriyle, model seçim riskinin azaltılarak daha stabil tahmin sonuçlarının elde edilebileceği görülmüştür. Litecoin kripto parasına yönelik modellemelerde, son iki yıl verisiyle ANFIS modeliyle mutlak bir üstünlük sağlanmıştır. Ripple kripto parasıyla Litecoin para birimine benzer sonuçlar elde edilmiş olmakla beraber, Ethereum para birimi nispeten en kötü sonuçların elde edildiği seri olmuştur. Sonuç olarak, Bitcoin en iyi sonuçların elde edildiği para birimi olmuştur. Diğer serilerde rassal yürüyüşün daha egemen olduğu belirlenmiştir. Ayrıca, serilere ait mevcut tüm verinin kullanılması yerine son döneme ait verilerin kullanılmasının özellikle trendin yakalanması anlamında daha yarar sağlayacağı gözlemlenmiştir.

Kripto para piyasasında tahmin yapmak hisse senedi piyasası ile kıyaslandığında, çok büyük bir avantaja sahiptir. Kripto paralar iş hayatındaki olaylardan veya hükümet müdahalelerinden bağımsızdır. Bu paranın fiyatları, onlara ulaşma zorluğu (kıtılığı) tarafından belirlenir. Karar verici ve politika yapıcılar açısından bakıldığında, kullanılabilir doğru tahmin modelinin belirlenmesi, sanal para fiyatının tahmin edilmesinde bir fırsat sağlayacak ve piyasadaki ilgili belirsizliği azaltacaktır. Bu açıdan bakıldığında, bu çalışmadan anlaşıldığı üzere en yaygın kullanıma sahip dört kripto para arasında tahmin edilebilirliği en yüksek para birimi Bitcoin olmuştur. Dolayısıyla, çalışmada kullanılan teknikler yardımıyla karar vericiler bu para biriminin belirsizliğini daha kontrol altına alabilir. Gelecek çalışmalar için, bazı sosyal medya veya diğer internet platformlarındaki kullanıcı verileri kullanarak Bitcoin fiyatındaki dalgalanmalar ile kullanıcı görüşleri arasındaki korelasyon bulunmaya çalışarak yeni bir değişken modellemeye katılabilir. Ayrıca GARCH-MIDAS modelleme tekniğinden faydalanılarak Bitcoin piyasasındaki oynaklık ölçülebilir.

## 7. KAYNAKÇA

- Alessandretti, L., ElBahrawy, A., Aiello, L. M., & Baronchelli, A. (2018). Anticipating cryptocurrency prices using machine learning. *Complexity*, 2018.
- Almeida, J., Tata, S., Moser, A., & Smit, V. (2015). Bitcoin prediction using ANN. *Neural networks*, 1-12.
- Andrews, D. W. (1993). Tests for parameter instability and structural change with unknown change point. *Econometrica: Journal of the Econometric Society*, 61(4), 821-856.
- Andrews, D. W., & Ploberger, W. (1994). Optimal tests when a nuisance parameter is present only under the alternative. *Econometrica: Journal of the Econometric Society*, 62(6), 1383-1414.
- Aras, S., & Gülay, E. (2017). A new consensus between the mean and median combination methods to improve forecasting accuracy. *Serbian Journal*

*of Management*, 12(2), 217-236.

Aras, S., & Kocakoç, İ. D. (2016). A new model selection strategy in time series forecasting with artificial neural networks: IHTS. *Neurocomputing*, 174, 974-987.

Aras, S., Deveci Kocakoç, İ., & Polat, C. (2017). Comparative study on retail sales forecasting between single and combination methods. *Journal of Business Economics and Management*, 18(5), 803-832.

Aras, S., Nguyen, A., White, A., & He, S. (2017). Comparing and Combining MLP and NEAT for Time Series Forecasting. *İstanbul Üniversitesi İşletme Fakültesi Dergisi*, 46(2), 147-160.

Armstrong, J. S. (Ed.). (2001). *Principles of forecasting: a handbook for researchers and practitioners* (Vol. 30). Springer Science & Business Media.

Baek, C., & Elbeck, M. (2015). Bitcoins as an investment or speculative vehicle? A first look. *Applied Economics Letters*, 22(1), 30-34.

Bai, J. (1997). Estimating multiple breaks one at a time. *Econometric theory*, 13(03), 315-352.

Bai, J., & Perron, P. (1998). Estimating and testing linear models with multiple structural changes. *Econometrica*, 66(1), 47-78.

Bakar, N. A., & Rosbi, S. (2017). High Volatility Detection Method Using Statistical Process Control for Cryptocurrency Exchange Rate: A Case Study of Bitcoin. *The International Journal of Engineering and Science*, 6(11), 39-48.

Bates, J. M., & Granger, C. W. (1969). The combination of forecasts. *Journal of the Operational Research Society*, 20(4), 451-468.

Box, G. E. P., & Jenkins, G. (1970). *Time Series Analysis, Forecasting and Control*. Holden-Day, San Francisco, CA.

Boyacioglu, M. A., & Avci, D. (2010). An adaptive network-based fuzzy inference system (ANFIS) for the prediction of stock market return: the case of the Istanbul stock exchange. *Expert Systems with Applications*, 37(12), 7908-7912.

Buchholz, M., Delaney, J., Warren, J., & Parker, J. (2012). Bits and Bets, Information, Price Volatility, and Demand for Bitcoin. *Economics*, 312, 2-48.

Catania, L., & Grassi, S. (2017). Modelling crypto-currencies financial time-series.. CEIS Working Paper, 15 Mayıs 2018 tarihinde <https://ssrn.com/abstract=3084109> adresinden erişildi.

Chang, J. R., Wei, L. Y., & Cheng, C. H. (2011). A hybrid ANFIS model based on AR and volatility for TAIEX forecasting. *Applied Soft Computing*, 11(1), 1388-1395.

Chow, G. C. (1960). Tests of equality between sets of coefficients in two linear regressions. *Econometrica: Journal of the Econometric Society*, 28, 591-

605.

Clemen, R. T. (1989). Combining forecasts: A review and annotated bibliography. *International journal of forecasting*, 5(4), 559-583.

Clements, M. P., & Hendry, D. F. (2001). *Forecasting non-stationary economic time series*. MIT press.

FATF (Financial Action Task Force), (2014). Virtual Currencies: Key Definitions and Potential AML/CFT Risks. 10 Mart 2018 tarihinde [www.fatf-gafi.org/media/fatf/documents/reports/Virtual-currency-key-definitions-and-potential-aml-cft-risks.pdf](http://www.fatf-gafi.org/media/fatf/documents/reports/Virtual-currency-key-definitions-and-potential-aml-cft-risks.pdf) adresinden erişildi.

Coinmarketcap (2018). 16 Nisan 2019 tarihinde [www.coinmarketcap.com/currencies/bitcoin/historical-data](http://www.coinmarketcap.com/currencies/bitcoin/historical-data) adresinden erişildi.

Currencycalculate (2018). 16 Nisan 2019 tarihinde [www.currencycalculate.com/tr/ethereum/](http://www.currencycalculate.com/tr/ethereum/) adresinden erişildi.

Granger, C. W. J., & Newbold, P. (2014). *Forecasting economic time series*. Academic Press.

Gronwald, M. (2014). The economics of Bitcoins: Market characteristics and price jumps. CESifo Working Paper Series No. 5121.

Hagan, M. T., Demuth, H. B., & Beale, M. H. (1996). *Neural network design*. Boston: PWS publishing company.

Harvey, A. (1997). Trends, cycles and autoregressions. *The Economic Journal*, 107(440), 192-201.

Hegazy, K., & Mumford, S. (2016). *Comparitive Automated Bitcoin Trading Strategies*. CS229 Project, 2016, 27 Nisan 2018 tarihinde [www.divaportal.org/smash/get/diva2:1110776/FULLTEXT01.pdf](http://www.divaportal.org/smash/get/diva2:1110776/FULLTEXT01.pdf) adresinden erişildi.

Hsu, C. W., & Lin, C. J. (2002). A comparison of methods for multiclass support vector machines. *IEEE transactions on Neural Networks*, 13(2), 415-425.

Hyndman, R., & Khandakar, Y. (2008). Automatic time series forecasting: The forecast package for R, *Journal of Statistical Software*, 27(3): 1–22.

Hyndman, R. J., Koehler, A. B., Snyder, R. D., & Grose, S. (2002). A state space framework for automatic forecasting using exponential smoothing methods, *International Journal of Forecasting*, 18(3): 439–454.

Hyndman, R. J., Koehler, A. B., Ord, J. K., & Snyder, R. D. (2008). *Forecasting With Exponential Smoothing: The state Space Approach*. Berlin: Springer.

Indera, N. I., Yassin, I. M., Zabidi, A., & Rizman, Z. I. (2017). Non-linear autoregressive with exogeneous input (NARX) Bitcoin price prediction model using PSO-optimized parameters and moving average technical

indicators. *Journal of Fundamental and Applied Sciences*, 9(3S), 791-808.

Jang, J. S. (1993). ANFIS: adaptive-network-based fuzzy inference system. *IEEE transactions on systems, man, and cybernetics*, 23(3), 665-685.

Jang, H., & Lee, J. (2017). An empirical study on modeling and prediction of bitcoin prices with bayesian neural networks based on blockchain information. *Ieee Access*, 6, 5427-5437.

Jose, V.R.R., & Winkler, R.L. (2008). Simple robust averages of forecasts: some empirical results. *International Journal of Forecasting*, 24, 163-169.

Kaastra, I., & Boyd, M. (1996). Designing a neural network for forecasting financial and economic time series. *Neurocomputing*, 10(3), 215-236.

Karakoyun, E. S., & Cibikdiken, A. O. (2018, May). Comparison of ARIMA Time Series Model and LSTM Deep Learning Algorithm for Bitcoin Price Forecasting. In *The 13th Multidisciplinary Academic Conference in Prague 2018 (The 13th MAC 2018)* (pp. 171-180).

Kim, K. J. (2003). Financial time series forecasting using support vector machines. *Neurocomputing*, 55(1-2), 307-319.

Kriptoparapiyasası (2018). 16 Nisan 2018 tarihinde [www.kriptoparapiyasasi.com](http://www.kriptoparapiyasasi.com) adresinden erişildi.

Larreche, J.C., & Moinpour, R. (1983). Managerial judgment in marketing: the concept of expertise. *Journal of Marketing Research*, 20, 110-121.

Liu, J., Wu, S., & Zidek, J. V. (1997). On segmented multivariate regression. *Statistica Sinica*, 7, 497-525.

Makridakis, S., Andersen, A., Carbone, R., Fildes, R., Hibon, M., Lewandowski, R., ... & Winkler, R. (1982). The accuracy of extrapolation (time series) methods: Results of a forecasting competition. *Journal of forecasting*, 1(2), 111-153.

Mercer, B. A. (1909). XVI. Functions of positive and negative type, and their connection the theory of integral equations. *Phil. Trans. R. Soc. Lond. A*, 209(441-458), 415-446.

Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2015). *Introduction to time series analysis and forecasting*. John Wiley & Sons.

Munim, Z. H., Shakil, M. H., & Alon, I. (2019). Next-Day Bitcoin Price Forecast. *Journal of Risk and Financial Management*, 12(2), 103.

Müller, K. R., Smola, A. J., Rätsch, G., Schölkopf, B., Kohlmorgen, J., & Vapnik, V. (1997, October). Predicting time series with support vector machines. In *International Conference on Artificial Neural Networks* (pp. 999-1004). Springer, Berlin, Heidelberg.

Nakamoto, S. (2008). *Bitcoin: A Peer-to-Peer Electronic Cash System*. The Cryptography Mailing List. 10.03.2018 tarihinde

[www.bitcoin.org/bitcoin.pdf](http://www.bitcoin.org/bitcoin.pdf) adresinden erişildi.

Newbold, P., & Granger, C. W. (1974). Experience with forecasting univariate time series and the combination of forecasts. *Journal of the Royal Statistical Society. Series A (General)*, 131-165.

Ord, J. K., Koehler, A. B., & Snyder, R. D. (1997). Estimation and prediction for a class of dynamic nonlinear statistical models, *Journal of the American Statistical Association*, 92(440): 1621–1629.

Palm, F. C., & Zellner, A. (1992). To combine or not to combine? Issues of combining forecasts. *Journal of Forecasting*, 11(8), 687-701.

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors, *Nature*, 323, 533–536.

Stock, J. H., & Watson, M. W. (1999). Cointegration, causality and forecasting, in R. F. Engle, H. White (Eds.). *A comparison of linear and nonlinear models for forecasting macroeconomic time series*. Oxford: Oxford University Press, 1–44.

Stock, J. H., & Watson, M. W. (2004). Combination forecasts of output growth in a seven-country data set. *Journal of Forecasting*, 23(6), 405-430.

Suykens, J. A., & Vandewalle, J. (1999). Least squares support vector machine classifiers. *Neural processing letters*, 9(3), 293-300.

Tay, F. E., & Cao, L. (2001). Application of support vector machines in financial time series forecasting. *Omega*, 29(4), 309-317.

Timmermann, A. (2006). Forecast combinations, in: G.Elliott, C.Granger, A. Timmermann (Eds.), pp. 135–196, *Handbook of Economic Forecasting*, Elsevier.

Valencia, F., Gómez-Espinosa, A., & Valdés-Aguirre, B. (2019). Price Movement Prediction of Cryptocurrencies Using Sentiment Analysis and Machine Learning. *Entropy*, 21(6), 589.

Vapnik, V. N. (1995). *The Nature of Statistical Learning Theory*, Springer Verlag, Berlin.

Walczak, S. (2001). An empirical analysis of data requirements for financial forecasting with neural networks. *Journal of management information systems*, 17(4), 203-222.

Wallis, K. F. (2011). Combining forecasts—forty years later. *Applied Financial Economics*, 21(1-2), 33-41.

Wang, H., & Hu, D. (2005, October). Comparison of SVM and LS-SVM for regression. In *Neural Networks and Brain, 2005. ICNN&B'05. International Conference on* (Vol. 1, pp. 279-283). IEEE.

Wilcox, R. R. (2012). *Introduction to robust estimation and hypothesis testing*. Academic Press.



Yao, Y. C. (1988). Estimating the number of change-points via Schwarz' criterion. *Statistics & Probability Letters*, 6(3), 181-189.

Yazdani-Chamzini, A., Yakhchali, S. H., Volungevičienė, D., & Zavadskas, E. K. (2012). Forecasting gold price changes by using adaptive network fuzzy inference system. *Journal of Business Economics and Management*, 13(5), 994-1010.

Yelowitz, A., & Wilson, M. (2015). Characteristics of Bitcoin users: an analysis of Google search data. *Applied Economics Letters*, 22(13), 1030-1036.

Yermack, D. (2015). Is Bitcoin a real currency? An economic appraisal. In *Handbook of digital currency* (pp. 31-43).

Zeileis, A., Kleiber, C., Krämer, W., & Hornik, K. (2003). Testing and dating of structural changes in practice. *Computational Statistics & Data Analysis*, 44(1-2), 109-123.

Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.

Zhang, G.P., Patuwo, B.E., & Hu, M.Y. (1998). Forecasting with Artificial Neural Networks: The State of The Art. *International Journal of Forecasting*, 14, 35-62.

Zhang, G. P., Patuwo, B. E., & Hu, M. Y. (2001). A simulation study of artificial neural networks for nonlinear time-series forecasting. *Computers & Operations Research*, 28(4), 381-396.

Zou, H., & Yang, Y. (2004). Combining time series models for forecasting. *International journal of Forecasting*, 20(1), 69-84.