

**T.C.
DOKUZ EYLÜL ÜNİVERSİTESİ
SOSYAL BİLİMLER ENSTİTÜSÜ
EKONOMETRİ ANABİLİM DALI
EKONOMETRİ PROGRAMI
YÜKSEK LİSANS TEZİ**

**GELECEĞE BAKIŞ; BİTCOİN'İN DERİN ÖĞRENME YÖNTEMİYLE
MODELLENMESİ VE TAHMİNİ**

Meltem TEKİNAY

**Danışman
Prof. Dr. İpek DEVECİ KOCAKOÇ**

İZMİR – 2021

YEMİN METNİ

Yüksek Lisans Tezi olarak sunduğum “Geleceğe Bakış; Bitcoin’in Derin Öğrenme Yöntemiyle Modellenmesi ve Tahmini” adlı çalışmanın, tarafımdan, akademik kurallara ve etik değerlere uygun olarak yazıldığını ve yararlandığım eserlerin kaynakçada gösterilenlerden oluştuğunu, bunlara atıf yapılarak yararlanılmış olduğunu belirtir ve bunu onurumla doğrularım.

Tarih

.../.../.....

Meltem TEKİNAY

ÖZET

Yüksek Lisans Tezi

Geleceğe Bakış; Bitcoin'in Derin Öğrenme Yöntemiyle Modellenmesi ve Tahmini

Meltem TEKİNAY

Dokuz Eylül Üniversitesi

Sosyal Bilimler Enstitüsü

Ekonometri Anabilim Dalı

Ekonometri Programı

Para, her yüzyılda önemliydi ancak paranın birebir alternatifi bulunduğumuz yüzyılda önem kazanmıştır. Dünya ekonomisi artık somut paradan ayrılıp, kripto para ve sanal bankacılık sistemine kaymaktadır. Bu davranış son yıllarda oldukça hızlanmıştır çünkü insanlar nakit para yerine kart kullanım rahatlığına alışmıştır. Lojistik sisteminin gelişmesiyle kişi bulunduğu yerden dünyanın öbür ucundaki bir yerel satıcıdan alışveriş yapabilme imkanı bulmuştur. Üstelik bunun için çok ciddi farklar ödemesine gerek kalmamıştır. Bu küreselleşmenin, dünyayı tek bir para birimine doğru götürdüğünü söylemek çok yanlış olmayacaktır. Döviz kurunda yaşanan ani değişimler, bir ürünün farklı pazarlarda çok farklı fiyatlarla yer alması, işçi emeğinin dünyanın farklı bölgelerinde farklı ücretlere tabi tutulması gibi birçok durum insanlar için zorlayıcı olmaya başlamıştır. Bu ve diğer sorunların çözümü olarak ise küresel para birimine geçiş gösterilmektedir ve gösterilmeye devam edecektir. Bunun için mevcut sistemin önce çöküp sonra yeni sistemin kurulması gerekmektedir. Yeni para biriminin Bitcoin olup olmayacağı henüz tartışma konusudur ancak önümüzdeki on yılda şuanki para sisteminin artık kullanılmayacağına kesin gözüyle bakılmaktadır.

Bu çalışmada Bitcoin ve onun ilişkili olabileceği düşünülen altcoin, döviz kurları, dünyaca ünlü borsalar ve emtialarla eşbütünleşme analizi yapılmıştır. Eşbütünleşme olduğu görülen değişkenlerin nedensellik analizleri tamamlanmış ve derin öğrenme metodu yapay sinir ağı modeline uygulanarak Bitcoin fiyatlarının 31, 45 ve 60 günlük tahminlenmesi gerçekleştirilmiştir.

Anahtar Kelimeler: Bitcoin, Derin Öğrenme, Kripto Para, Eşbütünleşme



ABSTRACT

Master's Thesis

**Dokuz Eylul University
Graduate School of Social Sciences
Department of Econometrics
Econometrics Program**

Meltem TEKINAY

Looking to the Future; Modelling and Prediction of Bitcoin with Deep Learning

Money has been important in every century, but the one-to-one alternative to money has gained importance in the current century. The world economy is now shifting from tangible money to crypto money and virtual banking system. This behavior has accelerated in recent years as people have become accustomed to the convenience of using cards instead of cash. With the development of the logistics system, people have had the opportunity to shop from a local dealer on the other side of the world. Moreover, there is no need to pay very serious differences for this. It would not be wrong to say that this globalization is driving the world towards a single currency. Sudden changes in the exchange rate, the availability of a product in different markets with very different prices, and the subjection of labor to different wages in different parts of the world have become challenging for people. As a solution to these and other problems, the transition to the global currency is and will continue to be shown. For this, firstly the current system should be collapsed and then the new system need to be installed. Whether the new currency will be Bitcoin is still a matter of debate, but it is certain that the current monetary system will no longer be used in the next decade.

In this study, a cointegration analysis with Bitcoin and altcoin, which is thought to be related to it, with exchange rates, world-famous stock markets and commodities has been performed. The causality analyzes of the variables that were found to be cointegrated were completed and the deep learning method was

applied to the artificial neural network model, and the 31, 45 and 60-day forecast of Bitcoin prices were made.

Keywords: Bitcoin, Deep Learning, Cryptocurrency, Cointegration



GELECEĐE BAKIŐ; BİTCOİN'İN DERİN ÖĐRENME YÖNTEMİYLE MODELLENMESİ VE TAHMİNİ

İÇİNDEKİLER

TEZ ONAY SAYFASI	ii
YEMİN METNİ	iii
ÖZET	iv
ABSTRACT	vi
İÇİNDEKİLER	viii
KISALTMALAR	xii
TABLolar LİSTESİ	xiv
ŐEKİLLER LİSTESİ	xv
EKLER LİSTESİ	xvi
GİRİŐ	1

BİRİNCİ BÖLÜM PARA VE ALTERNATİFLERİ

1.1. PARA	4
1.1.1. Elektronik Para	5
1.1.2. Sanal Para	5
1.1.3. Dijital Para	6
1.1.4. Kripto Para ve Blokzinciri Teknolojisi	7
1.1.4.1. Bitcoin	8
1.1.4.2. Bitcoincash	12
1.1.4.3. Ethereum	13
1.1.4.4. Dash	13
1.1.4.5. Decred	14
1.1.4.6. Nem	14

1.1.4.7. Tether	14
1.1.4.8. Vechain	15
1.1.4.9. Litecoin	15
1.1.4.10. Ripple	15
1.2. LİTERATÜR TARAMASI	16

İKİNCİ BÖLÜM ZAMAN SERİLERİ

2.1. ZAMAN SERİLERİ	20
2.1.1. Trend	20
2.1.2. Mevsimsellik	21
2.1.3. Konjonktürel Dalgalanma	22
2.1.4. Düzensiz Hareketler	22
2.2. Durağanlık	23
2.3. Matematiksel Tahminleme	24
2.4. Performans Ölçütleri	25
2.4.1. Ortalama	25
2.4.2. Korelasyon	26
2.4.3. Belirlilik Katsayısı	26
2.4.4. F-Testi	26
2.5. Koentegrasyon (Eşbütünleşme)	28
2.5.1. Engle-Granger Testi	28
2.5.2. Johansen Testi	28
2.5.3. Vektör Otoregresyon Modeli	30
2.5.4. Granger Nedensellik Testi	31

ÜÇÜNCÜ BÖLÜM YAPAY SİNİR AĞLARI VE DERİN ÖĞRENME

3.1. YAPAY SİNİR AĞLARI	32
3.1.1. Yapay Sinir Ağı Terminolojisi	33

3.1.2. Yapay Sinir Ađı Sınırlamaları	38
3.1.3. Yapay Sinir Ađının Avantajları	39
3.1.4. Yapay Sinir Ađlarının Ana Yapısı	39
3.1.4.1. Girdi Katmanı	40
3.1.4.2. Gizli Katman	40
3.1.4.3. Çıktı Katmanı	40
3.2. YAPAY SİNİR AđI ÖĞRENME YAPILARI	40
3.2.1. Denetimli Öğrenme	40
3.2.2. Denetimsiz Öğrenme	41
3.3. YAPAY SİNİR AđLARINDA ÖĞRENME KURALLARI	41
3.3.1. Hobfield Öğrenme Kuralı	41
3.3.2. Boltzmann Öğrenme Kuralı	41
3.3.3. Hebbian Öğrenme Kuralı	42
3.3.4. Kohonen Öğrenme Kuralı	42
3.4. TEK KATMANLI SİNİR AđI	42
3.5. ÇOK KATMANLI SİNİR AđI	43
3.6. YİNELEMELİ/TEKRARLAYAN AđLAR	45
3.7. YAPAY SİNİR AđI ALGORİTMALARI	46
3.7.1. Adaline ve Madaline	46
3.7.2. Algılayıcı	48
3.7.3. Geri Yayılım (Backpropagation)	48
3.8. DERİN ÖĞRENME	48
3.8.1. Derin Öğrenmenin Tarihçesi	49
3.8.2. Derin Öğrenme Tipleri	49
3.8.2.1. Evrişimsel Sinir Ađları	49
3.8.2.2. Uzun-Kısa Dönem Hafızalı Ađlar	50
3.8.2.3. Kapılı Tekrarlayan Hücre Ađı	50
3.8.3. Optimizasyon Algoritmaları	50
3.8.3.1. En Dik İniş Algoritması	51
3.8.3.2. Adam Algoritması	51
3.8.3.3. AdaGrad Algoritması	52
3.8.3.4. Ortalama Karekök Yayılma Algoritması	52

3.8.4. Öğrenme Oranı	52
3.8.5. MATLAB Derin Öğrenme Aracı	53

DÖRDÜNCÜ BÖLÜM

UYGULAMA

4.1. UYGULAMANIN AMACI	57
4.2. VERİLER VE ANALİZ YÖNTEMLERİ	57
4.2.1. Temel İstatistikler	58
4.2.2. Engle – Granger Eşbütünleşme Testi	59
4.2.3. Granger Nedensellik Testi	61
4.2.4. Yapay Sinir Ağı ve Derin Öğrenme	63
4.3. MODELLER	63
4.4. ANALİZ SONUÇLARI VE YORUMLAR	68
SONUÇ	74
KAYNAKÇA	76
EKLER	ek s.1

KISALTMALAR

ABD	Amerika Birleşik Devletleri
ADALINE	Adaptive Linear Neuron
ADAM	Adaptive Moment Estimation
ADF	Augmented Dickey Fuller
AIC	Akaike Information Criteria
ANN	Artificial Neural Network
BCH	Bitcoincash
BIC	Binomial Information Criteria
BiLSTM	Bidirectional Long – Short Term Memory
BRNN	Bidirectional Recurrent Neural Network
BTC	Bitcoin
CNN	Convolutional Neural Network
CPU	Central Process Unit
DASH	Dash
DCR	Decred
DLT	Distributed Ledger Technology
ETH	Ethereum
GRU	Gated Recurrent Unit
LSTM	Long – Short Term Memory
LTC	Litecoin
M.Ö.	Milattan Önce
MADALINE	Many Adaptive Linear Neuron

MAPE	Mean Absolute Percentage Error
MB	Megabayt
MIT	Massachusetts Institute of Technology
MLP	Multilayer Perceptron
NEM	XEM
OKY	Ortalama Karekök Yayılma
PPMC	Pearson Product Moment Correlation
ReLU	Rectified Linear Activation Function
RMSE	Root Mean Square Error
RMSprop	Root Mean Square Propagation
RNN	Recurrent Neural Network
SGD	Stochastic Gradient Descent
SOM	Self Organizing Map
SVM	Support Vector Machines
USDT	Tether
VAR	Vector Autoregression
VET	VeChain Token
VTHO	VeChainThor Energy
XMR	Monero
XRP	Ripple
YSA	Yapay Sinir Ağı

TABLÖLAR LİSTESİ

Tablo 1: Temel İstatistikler	s. 58
Tablo 2: Birim Kök Testi ve Eşbütünlük Testi Sonuçları	s. 60
Tablo 3: Granger Nedensellik Testi Sonuçları	s. 61
Tablo 4: 31 Günlük Tahmin İstatistikleri	s. 67
Tablo 5: 45 Günlük Tahmin İstatistikleri	s. 67
Tablo 6: 60 Günlük Tahmin İstatistikleri	s. 68
Tablo 7: Model Performans Karşılaştırması	s. 71



ŞEKİLLER LİSTESİ

Şekil 1: Bitcoin İşlem Görseli	s. 9
Şekil 2: Zaman Damgası Sunucusu Görseli	s. 10
Şekil 3: İş Kanıtı Görseli	s. 11
Şekil 4: Gizlilik Modelleri	s. 12
Şekil 5: Zaman Serisi Bileşenleri	s. 20
Şekil 6: Trend	s. 21
Şekil 7: Mevsimsellik	s. 21
Şekil 8: Konjonktürel Dalgalanma	s. 21
Şekil 9: Düzensiz Etki	s. 21
Şekil 10: Biyolojik Nöron Modeli	s. 21
Şekil 11: Genelleştirilmiş Matematiksel Model	s. 22
Şekil 12: Yapay Sinir Ağı Kategorileri	s. 23
Şekil 13: Çok Katmanlı Ağ – Basit Doğrusal Olmayan Regresyon	s. 33
Şekil 14: Yinelemeli Sinir Ağı Modeli	s. 35
Şekil 15: ADALINE Yapısı	s. 36
Şekil 16: MATLAB Katmanlar	s. 54
Şekil 17: MATLAB Ağ Analizi	s. 56
Şekil 18: Granger Nedensellik Testi Şeması	s. 63
Şekil 19: Bitcoincash ve Bitcoin Modeli 1. Deneme Sonucu	s. 64
Şekil 20: Bitcoincash ve Bitcoin Modeli Grafiği – 31 Günlük	s. 64
Şekil 21: Bitcoincash ve Bitcoin Modeli Grafiği – 45 Günlük	s. 65
Şekil 22: Bitcoincash ve Bitcoin Modeli Grafiği – 60 Günlük	s. 66
Şekil 23: Bitcoincash ve Bitcoin Modeli Tahmin Grafiği	s. 67
Şekil 24: BCHBTC Modeli için CUSUM Test	s. 69
Şekil 25: DCRBTC Modeli için CUSUM Test	s. 69
Şekil 26: XEMBTC Modeli için CUSUM Test	s. 70
Şekil 27: ETHBTC Modeli için CUSUM Test	s. 71
Şekil 24: DCR - BTC Gerçekleşme ve Tahmin Karşılaştırması	s. 71
Şekil 25: ETH - BTC Gerçekleşme ve Tahmin Karşılaştırması	s. 72
Şekil 26: BCH - BTC Gerçekleşme ve Tahmin Karşılaştırması	s. 72

EKLER LİSTESİ

EK 1: Küresel Para Birimine Hazır Olun

ek s.1



GİRİŞ

Gelişmekte olan teknoloji ile en önemli devrimlerden bir tanesi finansal sistemde gerçekleşmektedir. İcadından günümüze kadar geçen sürede *paranın* somut bir varlık olması, paraya bir kıymet olarak duyulan güvenin en büyük nedenlerinden birisi olmuştur. Bankacılık sisteminin geçtiğimiz yıllarda elektronik ortama aktarımı, kullanıcı ve bankacıların çoğu yönden işlerini hızlandırmış ve kolaylaştırmış olmasıyla birlikte günümüzdeki *sanal para* algısına daha kolay şekilde alışılmasına neden olmuştur. İnternet üzerinde gerçekleştirilen para aktarım işlemleri, kredi alımı/ödemesi, kredi kartı işlemleri, fatura ödemesi, döviz/menkul kıymet ticareti gibi işlemlerinin temelini somut para oluşturmaktadır. Son 10 senede gerçekleşen teknolojik gelişmeler tüm dünyadaki parasal sistemin çöküşüne neden olacak veya alternatifini oluşturacak boyutta yaşanmaktadır. Öyle ki yakın gelecekte nakit paranın yerini, dijital platformlarda kullanılan dijital paraların alacağını öngören araştırmacı ve bilim insanları mevcuttur. Bu radikal değişimin gerçekleşip gerçekleşmeyeceği konusunda kesin bir görüş birliği sağlanamamakla birlikte ekonomisi güçlü ülkelerin dijital para sistemi hakkında olası riskleri ve avantajları tartışıp, gelecekteki dijital paranın rolü için çalışmaları devam etmektedir.

Weatherford, 1997'deki makalesinde şunları belirtmiştir; “Dolar yen, luro ve diğer ulusal para birimleri ölüyor. Küresel para sistemimize ölümcül bir virüs bulaşmış durumda ve halihazırda ciddi şekilde zayıfladı. Yirminci yüzyılın son yıllarında, küresel para sistemi öksürmeye, sarsılmaya ve tökezlemeye başladı. En güçlü ve en sağlıklı para birimlerinin döviz kurları kontrolsüz bir şekilde sallanırken, birkaç zayıf ulusun para birimleri beklenmedik bir şekilde hastalandı. Bankalar, Rönesans'tan bu yana dünyanın en büyük finans kurumları olarak hüküm sürdükten sonra, bir gecede açıklanamaz bir şekilde gerçekleşmiş gibi görünen milyar dolarlık kayıpların altına düştüler. Birleşik Devletler, yükselen ulusal bir çöküşü, artan ticaret dengesizliklerini, dönemsel enflasyon dalgalarını ve doların değerinde uzun vadeli düşüşü desteklemeye devam etti. Pek çok düzeyde oldukça tuhaf ama kapsamlı müdahalelere rağmen, hiçbir hükümet kendi para birimini kontrol edemiyor gibi görünmekte ve yeni finans kurumları, tarihte daha önce hiç bilinmeyen bir güce sahip birbirine bağlı işletmelerden oluşan bir ağda artık dünyanın her yerinde ayakta durmaktadır. Uluslararası Para Fonu, Birleşmiş Milletler ve Dünya Bankası gibi sözüm ona küresel kuruluşlar, halihazırda

uluslararası güçlükte olan en zayıf oyuncular dışında herhangi birinin finansmanıya büyük ölçüde ilgisiz görünmektedir.”

Para, insanlık için hep somut bir olguydu. Bu hiçbir zaman değişmedi çünkü bulunduğumuz evrendeki dünya materyalist bir düzene aittir. Günümüzdeki modern hayat da temel olarak somut paranın çevresinde dönmektedir, şimdilik. Dünya ekonomilerinde yaşanan şiddetli depremler sonrası çoğu ekonomist bugünleri on yıllar öncesinden görmüş olacaklar ki, hali hazırda kullanmaya devam ettiğimiz para sisteminin çöküşünün gerçekleşeceğini bildirmişlerdir. 1988 yılında The Economist dergisinde yayınlanan (“Get Ready For The Phoenix”, 1988) “Anka Kuşuna Hazırlıklı Olun” isimli makalede mevcut ekonomik sistemin insanları daha ileriye götüremeyeceği ve yaşanacak birkaç kriz sonrası insanların farklı bir sisteme geçiş yapmak zorunda kalacakları anlatılmaktadır. Öyle ki makalenin yayınlandığı 1988 yılından sonraki 30 sene içerisinde Amerikalılar, Japonlar, Avrupalı ve diğerlerine göre nispeten zengin ülkelerde yaşayan insanların aynı para biriminden ödeme yapacakları belirtilmiştir. 1987 yılında yaşanan Kara Pazartesi ile DowJones endeksinin %22’lik sert kaybı bu makalede, karar vericilerin yaşanacak kaybı önceden görememesi olarak değerlendirilmiştir. Makalenin 2. Bölümünde tüm dünyada kullanılacak tek bir para biriminin avantajlarından bahsedilmiştir. Tek para biriminin kullanılmaya başlamasıyla kur riski ortadan kalkacağı için yatırım ve istihdamın artacağı görüşü bildirilmiştir. Makalede ayrıca 2018 yılına dikkat çekilmektedir. Makalede, 2018 yılından Anka kuşağı olarak bahsedilmektedir. Anka kuşağının tüm dünyaya tek bir para birimini getireceğini ve insanların bu para biriminin sağladığı rahatlığı tercih edecekleri anlatılmaktadır.

Anka kuşağının günümüzdeki yansıması öncelikle sanal para/internet bankacılığı olarak düşünülebilir. Günümüzde insanların para harcama alışkanlıklarına bakıldığında kart kullanımı, nakit para kullanımının üzerinde seyretmektedir (Kumar ve O’Brien, 2019). Artık belli başlı alım/satımlar hariç kişinin ihtiyaç duyabileceği tüm alışverişler internet üzerinden sanal kart/debit kart veya kredi kartı aracılığıyla yapılabilmektedir. İnsanların bu sisteme alışması aslında Bitcoin’e zemin hazırlanması olarak yorumlanabilir. Çünkü hali hazırdaki ekonomik sistem çöküş dönemine girmişti ve yakın tarihte bir sistem değişikliği yapılması gerekiyordu. 2017-2018 yıllarında

Bitcoin'in ani deęer kazanmasıyla tüm dünyada dikkatleri üzerine çekmiştir ve dünyada popülaritesinin artmasına neden olmuştur.

Bu çalışmanın amacı, Bitcoin'i yakından incelemek, tüm dünyada merak edilen Bitcoin'in farklı finansal araçlar tarafından etkilenip etkilenmedięi sorusuna bir ışık tutmak ve derin öğrenme yöntemi ile oluşturulan Bitcoin modelinin uzun vadede dengeye geldięi dięer finansal araçlarla kısa vadeli tahmin oluşturmak ve bu tahminlemenin performansını deęerlendirmektir.

Yapılan bu çalışmanın birinci bölümünde para ve çeşitleri incelenmiştir. Bazı önemli kripto paralar ele alınmış ve Bitcoin ve Bitcoin'in çalışma prensibine yer verilmiştir. İkinci bölümde zaman serileri ana başlığı altında temel regresyon analizi ve zaman serilerine yer verilmiştir. Zaman serileri konularından durağanlık, tahminleme ve performans ölçütleri de incelenmiş olup koentegrasyon konusu ele alınmıştır. Üçüncü bölümde yapay sinir aęları ve derin öğrenme konularına yer verilmiştir. Bölüm sonunda MATLAB R2019b sürümüne ait derin öğrenme araç kutusunun bazı kodları açıklanmıştır. Ardından literatür taraması ile bölüm tamamlanmıştır. Dördüncü bölümde uygulamanın amacı, veriler ve özellikleri ve analizler yer almaktadır. Uygulama kısmında MATLAB R2019b paket programı ile hazırlanmış Bitcoin modelinin grafiksel gösterimlerine yer verilmiştir. Sonuç bölümünde tez genel olarak ele alınmış, uygulamaya ait sonuçlar ve performans deęerlendirmeleri yapılmıştır.

BİRİNCİ BÖLÜM

PARA VE ALTERNATİFLERİ

1.1 PARA

Para, temel sosyal teknolojilerimizden biridir. Yazı ve sayının icadıyla birlikte para, M.Ö. otuz yıl boyunca eski Yakın Doğu'daki dünyanın ilk büyük ölçekli toplumlarının temeliydi ve bugün kelimenin tam anlamıyla küreselleşen dünyayı 'döndürmektedir'. Para, ekonomik ders kitabının tanıdık işlevler listesini yerine getirerek bu vazgeçilmez rolü oynamaktadır. Değişim aracı, değer sahibi ve değer ölçüsü (hesap birimi) aracıdır. Her özellik modern dünyada rutin yaşamın devamı için temel yapı taşıdır.

Para ilk olarak, Adam Smith'in ve klasik iktisatçıların açıkça belirttiği gibi, bir değişim aracı, iş bölümünün verimli işlenmesini ve "ulusların zenginliğini" yaratan ürünlerin değişimini sağlamaktadır. Bu dolaylı çok taraflı değişim, "çiftçinin işini berberin işine çevirme"nin bir yoludur. Bir diğer deyişle, para uzaktan eylemdir. İnsanların yaygın şekilde mübadele aracı olarak kullanılan bir şeye sahip olmasının nedeni, o şeyi istedikleri için değil başka şeyle değiştirme imkânı olmasıdır. Örneğin, İkinci Dünya Savaşı sırasında bazı savaş kamplarındaki esirlerde, paranın yokluğunda sigaralar bir mübadele aracı haline gelmiştir. Sigara içmeyenler bile sigarayla bir şeyler takas etmeye istekli olmaktadır ancak bu sigara içmeyi planladıkları için değil, daha sonra onların istedikleri bir şeyle değiştirebilecekleri için. İkincisi ve belki de en dikkat çekicisi, paranın soyut değeridir. Para, değerini zaman içerisinde korumaya devam eder. Bu özelliğin sonuçları modern dünyanın özgürlüğünü ve esnekliğini tanımlar. Yüzlerce yıl önce çıkarılan altın veya gümüş bugün de değerli olacaktır. Ancak çabuk bozulan yiyecekler zaman geçtikçe hızla değersiz hale gelir. Altın veya gümüş iyi değer depolarıdır, ancak çabuk bozulan yiyecekler çok daha azdır. Ancak tüm bu sonuçlar, ilke olarak, parasal hesaplama olanağına bağlıdır. Bir değer ölçüsü (paranın hesabı) olarak paranın bu üçüncü özelliği, fiili ve potansiyel maliyet ve faydaların, kar ve zararların, borçların, fiyatların hesaplanmasını sağlar. Modern ekonomilerde hesap birimi genellikle bir para birimidir, örneğin Birleşik Krallık'ta kullanılan pound ancak bunun yerine bir tür mal olabilir. Geçmişte, ürünler genellikle temel gıdalar (buğday) veya çiftlik hayvanları gibi çok yaygın olan bir şeye göre

fiyatlandırılırdı (Mcleay ve diğeri, 2014). Kısacası para, eski Mezopotamya imparatorluklarında başlayan sosyal yaşamın ilerici rasyonalizasyonunun temelidir(Ingham, 2004).

Dünyadaki çoğu insan, mal ve hizmet satın almak ya da satmak, ödeme yapmak ya da almak, sözleşme yazmak ya da uzlaşmak için günlük olarak bir tür para kullanır. Para, modern bir ekonominin işleyişinin merkezidir. Ancak önemi ve yaygın kullanımına rağmen, paranın gerçekte ne olduğu konusunda evrensel bir anlaşma yoktur. Bunun nedeni kısmen parayı oluşturan şeyin zaman içinde ve yerden yere değişmesidir.

1.1.1. Elektronik Para

Elektronik para (e-para) geniş anlamda, e-para düzenleyen kuruluş dışındaki kuruluşlara ödeme yapmak için yaygın olarak kullanılabilen, teknik bir cihazda parasal değeri olan elektronik bir mağaza olarak tanımlanır. Cihaz, işlemlerde mutlaka banka hesaplarını içermeyen, ön ödemeli bir hamiline aracı olarak işlev görür. E-para ürünleri, parasal değeri depolamak için kullanılan teknolojiye bağlı olarak donanım tabanlı veya yazılım tabanlı olabilir (European Central Bank).

Buluşa göre sistem, bir iletişim ağına bağlı bir elektronik parayı geçici olarak depolamak için bir bilgi işlem birimi (elektronik para sunucusu) ile donatılmıştır. Elektronik para sunucusu en az iletişim aracı, elektronik para işleme aracı ve depolama aracı içerir. Havale yapandan elektronik para sunucusuna havale ve elektronik para sunucusundan alıcıya havale olarak iki aşamada gerçekleştirilir. Bu elektronik para sunucusu, bir elektronik paranın havale işlemi aracısına kurulur. Örneğin, banka gibi bir finans kuruluşunun böyle bir hizmet sağlaması beklenir. Bu servis ücretsiz olarak veya belirli bir ücret karşılığında gerçekleştirilebilir. Önemli olan elektronik para sunucusuna elektronik para gönderiminin 24 saat boyunca gerçekleştirilebilmesi ve alınan elektronik paranın alıcıya havale etmek veya havale yapana iade etmek için güvenli bir şekilde saklanabilmesidir (Yacobi, 1995).

1.1.2. Sanal Para

Sanal para (virtual currency), geliştiriciler tarafından oluşturulan ve denetlenen, belirli bir (sanal) topluluğun üyeleri arasında kullanılan ve kabul edilen bir değer dijital temsilidir. Nakit paranın aksine, merkez bankası veya başka bir

bankacılık otoritesi tarafından desteklenmeyen bir güven sistemine dayanmaktadır (Sia Partners, 2015).

Para toplulukları, bir ekonomideki para arzını ölçen geniş kategorilerdir. Amerika Birleşik Devletleri'nde etiketler, standartlaştırılmış parasal toplamlara atfedilir:

M0: Para tabanı olarak da bilinen dolaşımdaki fiziksel kâğıt ve madeni para birimidir.

M1: Tüm M0, seyahat çekleri ve vadesiz mevduatlarıdır.

M2: M1'in tamamı, para piyasası payları ve tasarruf mevduatıdır.

100.000 Amerikan dolarının üzerindeki vadeli mevduatları ve kurumsal fonları da içeren M3 olarak bilinen eski bir toplam, 2006 yılından bu yana Federal Rezerv tarafından takip edilmemektedir, ancak yine de bazı analistler tarafından hesaplanmaktadır (Tarver, 2020).

Sanal para ve dijital para terimleri etrafında çok fazla kafa karışıklığı bulunmaktadır. Dijital paradan bahsederken, bu, finansal sistemin M2 ve M3 kategorileriyle ilgilidir (M1, dolaşımdaki fiziksel kâğıt paralar ve madeni paralardır). Dünya genelinde para birimlerinin%95'inden fazlası dijitaldir. Sanal para başlangıçta yalnızca gerçek dünyada yaşamayan ve yalnızca çevrimiçi olarak (genellikle online oyunlarda) takas edilen para birimlerine atıfta bulunur. Daha sonraki bir aşamada, sanal para birimleri fiziksel dünyaya genişlemeye başlamış ve sanal ile dijital para arasındaki çizgiyi bulanıklaştırmıştır. Çoğu devlet kurumu, sanal para birimine atıfta bulunsalar dahi dijital para birimi terimini kullanmayı tercih etmektedir(Sia Partners, 2015).

1.1.3. Dijital Para

Dijital para birimi (*digital currency*), Cambridge Dictionary tarafından internet üzerinden mal veya hizmetin ödemesini gerçekleştirmek amacıyla bir şirketten satın alınan dijital para olarak tanımlanmıştır. Dijital para, tamamen dijital biçimde var olan bir para birimidir. Nakit, altın, petrol veya diğer emtialar gibi somut bir varlık değildir. Dijital para, kripto para birimlerini içerebilir, ancak onlarla sınırlı değildir. Dünyada sahip olunan dijital paranın çoğu bankacılık kurumlarına aittir. Bankalar, çok sayıda fiziksel lokasyonda kira ödemeleri veya ihtiyaç duymadıkları perakende

çalışanları için ödeme yapmaya devam etmeleri gerekmediği için dijital para sayesinde iş maliyetlerini daha düşük tutabilmektedirler (Grant, 2020).

1.1.4. Kripto Para ve Blokzinciri Teknolojisi

Kripto para kelimesi, para biriminin kriptografi ile güvence altına alındığı gerçeğinden türetilmiştir. Modern kriptografi, rastgeleliğin ve olasılığın öngörülebilirliği engellediği ve böylece benzersiz bir güvenlik sağlayan tamamen matematiğe dayalı bir sistemdir. Sayılar, insanların bilgiyi ölçmesini sağlayan nesnel ve evrensel bir dildir. O kadar evrensel ki bilgisayarlar ve teknoloji bile sayıları anlamaktadır. Sayılar dijital engellerin inşa edilmesini sağlayabilmekte ve kriptografiyi böylesine güvenli bir sistem yapan şeyin temelini oluşturmaktadırlar (Corsello, 2018).

Kripto para birimlerinin çoğu, büyük ölçüde Bitcoin veya diğer kripto para birimlerinin klonlarıdır ve yalnızca farklı parametre değerlerine sahiptir (örneğin, farklı blok süresi, para arzı ve ihraç şeması). Bu kripto para birimleri çok az yenilik gösterir veya hiç göstermez ve genellikle “altcoin” olarak adlandırılmaktadır (Hileman ve Rauchs, 2017).

Blokzinciri (Blockchain) teknolojisi, bilginin güvenli şekilde saklanmasını sağlayan bir teknolojidir. Blok zinciri tabanlı platform çoğunlukla dağıtılmış bir defter, merkezi olmayan bir fikir birliği mekanizması ve kriptografik güvenlik önlemlerinden oluşur. Tüm taraflar, blok zinciri hesapları aracılığıyla doğrudan bilgi paylaşabilir ve işlem kayıtlarının kopyalarını tutabilir. İşlemler, adı verilen bir dizi kural aracılığıyla gerçekleştirilir ve onaylanır (Shafie-khah, 2020).

Blokzinciri teknolojisi hayatımıza ilk olarak kripto paralar ile girmiştir. Ancak kullanım alanı sadece kripto paralarla sınırlı değildir. Aşağıda, blokzincirinin uygulama alanlarından bazıları aktarılmaktadır (Khandelwal, 2021):

- Gıda Güvenliği: ürünlerin üretiminden nihai kullanıcıya kadar sürecin takip edilebilir olması gıda güvenliğini sağlamaktadır.
- Emlak Tapu İşlemleri: Tapularla ilgili işlemlerin kayıtlarının tutulmasında kolaylık sağlamaktadır.
- Dünyanın Farklı Yerlerindeki Para Transfer İşlemleri: Küresel anlamda nakit alışverişi oldukça maliyetli, uzun zaman alan ve güvenlik açığı oluşabilen bir sistemdedir. Blokzinciri teknolojisi ile

güvenli, hızlı, merkezi olmayan ve şeffaf şekilde herhangi bir aracı olmadan para transferi problemlerini çözmektedir.

- Mevzuata Uygunluk ve Denetim: Blokzincirinin sağlamış olduğu yüksek güvenlik, değişmezlik ve dışarıdan yapılabilecek herhangi bir değişikliğe karşı çözülmesi imkansız yapı ile bilgiler oldukları şekilde bozulmadan saklanabilmektedir.
- Tedarik Zinciri: Tedarik zincirinde bulunan tüm halkaların açık şekilde izlenebilirliği sayesinde sistem aksamadan devam etmektedir.

Blokzinciri teknolojisi aracısız şekilde iki taraf arasındaki tüm işlemlerin güvenli şekilde kaydedilmek istendiği tüm yerlerde uygulanabilir.

Blok zinciri teknolojisinin yapısal olarak yanıt verdiği ihtiyaç türünün ötesinde, bu teknoloji teknik bir sistem olarak bilgi işlem alanına aittir. Bitcoin kelimesi aynı zamanda, 0 ve 1'den oluşan hesaplamada temel ölçü birimi olan ikili rakamın kısaltması olan bit'e de bir referanstır (Quiniou, 2019).

1.1.4.1. Bitcoin

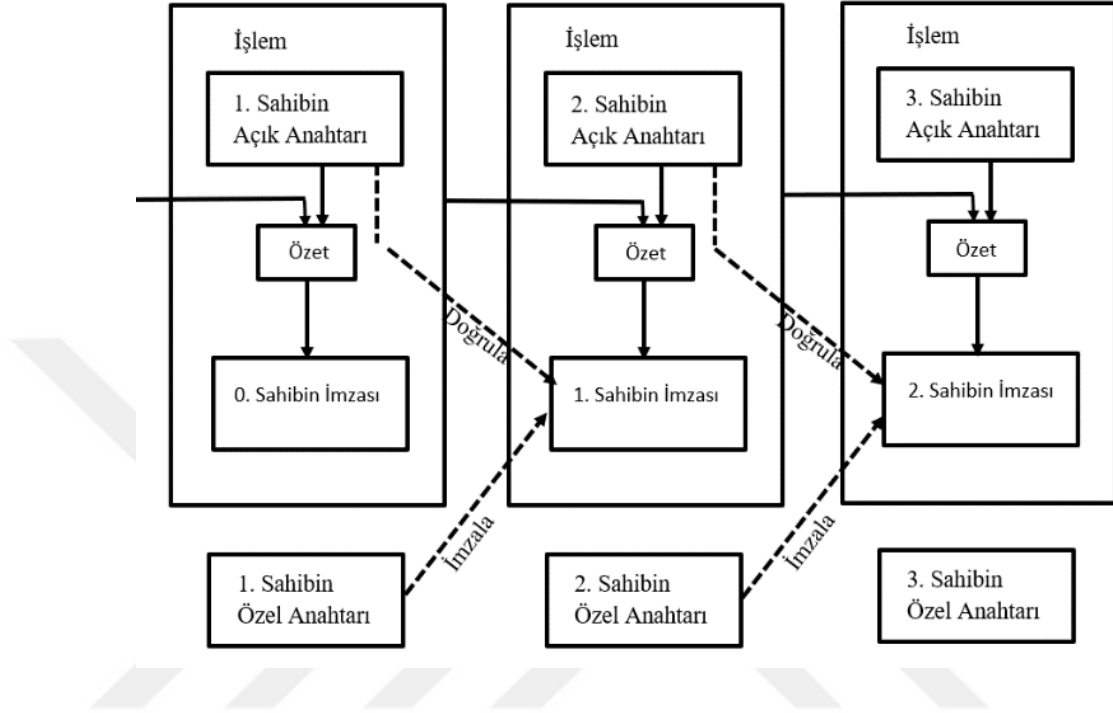
Bitcoin bilinen ilk kripto paradır. Ancak ondan öncesinde çeşitli sanal para girişimleri olmuştur. 1983 yılında Amerikan kriptograf David Chaum *ecash* adını verdiği anonim kriptoTablo elektronik parayı tasarlamıştır (Chaum, 1982). Ardından 1995 yılında, bankadan not almak ve alıcıya göndermeden önce belirli şifreli anahtar atamak için kullanıcı yazılımı gerektiren kriptoTablo elektronik ödemelerin bir formu olan *Digicash*'i bulmuştur ancak Digicash devlet, banka veya 3. Partiler tarafından kullanılamamaktaydı.

Ulusal Güvenlik Ajansı (NSA) 1996 yılında *Para Nasıl Basılır: Anonim Elektronik Para Kriptografisi* isimli makale ile kripto para sistemini ilk kez MIT (Massachusetts Institute of Technology) posta listesinde ve 1997'de Washington College of Law Review'da yayınlamıştır (Law ve diğerleri, 1996).

Bitcoin, 2008 yılında Satoshi Nakamoto isimli kişi ya da kişilerce yayınlanan "Bitcoin: Uçtan Uca Eklemeli Eletronik Ödeme Sistemi" makalesi ile ortaya konmuştur. Bu kısım orijinal makaleden tez konusuyla ilintili bölümler ele alınarak tamamlanmıştır.

Elektronik para, dijital imza zinciri olarak tanımlanmıştır. Her bir gönderici, bir önceki işlemi ve alıcının açık anahtarını imzalar ve sonraki imzaya aktarır. Alacaklı, zincirin sahipliğini doğrular ve böylece işlem tamamlanır.

Şekil 1: Bitcoin İşlem Görseli



Kaynak: Nakamoto, 2008.


Buradaki problem elbette ki alacaklı kişinin, göndericinin 2 defa ödeme yapıp yapmadığını bilememesidir. Genel çözüm, her işlemi çift ödeme olarak gerçekleştirilmediğine dair kontrol eden güvenilir bir merkezi otorite tanıtmaktır. Her bir işlem sonrası, (gönderilen) para yeni bir para yaratır ve sadece güvenilir merkezi otoriteden (darphane) gelir. Böylece çift ödeme gerçekleşmez. Bu çözümdeki problem ise işlem gören her bir paranın merkezi bir otorite üzerinden geçmesidir.

İhtiyaç olunan şey alacaklının, göndericinin önceden herhangi bir işleme izin verip vermediğinden haberdar olmasıdır. Bu durumda önemli olan en eski işlemidir. Sonradan gerçekleşen ikinci ödemelerle ilgilenilmez. Bu şekilde ikinci ödemelerin varlığından haberdar olabilmek için tüm işlemlerden haberdar olmak gerekir. Merkezi otoriteli modelde otorite tüm işlemlerden haberdardır ve hangi işlemin ilk geldiğini bilir. 3. Şahıs bir firma olmadan bunu kabul edebilmek için işlemler halka açıklanır ve tüm paydaşların/müşterilerin buna güvenmeleri için bir sisteme ihtiyaç vardır.

Alacaklı kişinin işlemin gerçekleştiği anda çoğu düğüm tarafından bu işlemin ilk alım olduğunu doğrulayacak kanıtı ihtiyacı olur.

Sunulan çözüm tarih bilgisi dağıtıcısı ile başlamaktadır. Tarih bilgisi sunucusu, tarih belirtilecek olan işlemlerden imza değeri alır ve bunu gazete veya Usenet gibi yerlerde yayınlar. Tarih sunucusu verinin tam o tarihte orada bulunduğunu kanıtlar. Her tarih bilgisi önceki işlemin sahip olduğu dijital imzayı içerir ve zincir formunu oluşturur. Her bir tarih bilgisi önceki işlemi güçlendirir.

Şekil 2: Zaman Damgası Sunucusu Görseli




Kaynak: Nakamoto, 2008.

Eşten eşe dağıtılmış tarih bilgisi sunucusunu iş kanıtı (proof-of-work) tabanlı oluşturmak istendiğinde, Adam Back'in yazmış olduğu Hashcash makalesindeki (Back, 2002) ispata benzer şekilde sistem yaratmak gerekir. İş kanıtı, örneğin SHA-256 ile dijital imzanın belli sayıda sıfır biti ile başlamasını gerektirir. Gerekli ortalama çalışma, gerekli olan ve tek bir imza çalıştırılarak doğrulanabilen sıfır bit sayısı ile üstel olarak orantılıdır.

Zaman damgası sunucusu için iş kanıtı, bloktaki dijital imza istenen sıfır bit sayısına ulaşıncaya kadar arttırılan bir tek kullanımlık sayı ile sağlanır. İş kanıtının sağlanması için işlemci gücü (CPU) bir kez arttırıldığında, blok yeniden işlem yapılmadığı sürece değiştirilemez. Bloklar zincire eklendiklerinde, önceki bloklara bağlı olacakları için bir bloğun değiştirilmesi, kendisinden önce gelen tüm blokların da değiştirilmesini gerektirir.

Şekil 3: İş Kanıtı Görseli



Kaynak: Nakamoto, 2008.

İş kanıtı aynı zamanda, karar vermede çoğunluğun temsil edilmesi problemini de çözer. Eğer çoğunluk bir-IP-bir-oy tabanlı olsaydı, çokça IP sahibi bir kişi tarafından sistem yıkılabilirdi. İş kanıtı esas olarak bir-CPU-bir-oy olarak çalışmaktadır. Çoğunluk kararı, en iyi iş kanıtı eforunu sağlayan en uzun zincir tarafından temsil edilir. Eğer işlemci gücünün büyük çoğunluğu doğru düğümler tarafından kontrol edilirse, doğru zincir hızlıca büyüyecek ve rakip zincirleri aşacaktır. Geçmişteki bloğu değiştirmeye çalışan bir korsan kullanıcı, o bloktan sonra tüm gelen blokları değiştirerek mevcutta bulunan dürüst zincirden çok daha büyük bir zincir oluşturması gerekecektir.

Ağı çalıştırmak için gerekli adımlar şu şekildedir:


- i. Yeni işlemler tüm düğümlere tanıtılır.
- ii. Her düğüm yeni işlemleri bloğun içerisine toplar.
- iii. Her düğüm kendi bloğu için iş kanıtı bulmaya çalışır.
- iv. Düğüm iş kanıtını bulduğunda bunu tüm düğümlere yayımlar.
- v. Düğüm bloğu sadece eğer tüm işlemler geçerli ve daha önce harcanmamış ise kabul eder.
- vi. Düğümler bir önceki dijital imzanın onaylanmış bloğunu kullanarak bir sonraki bloğu oluştururken bloğu onayladığını ifade eder.

Düğümler her zaman için en uzun zinciri doğru kabul eder ve onu genişletmek için çalışır. Eğer iki farklı düğüm bir bloğun iki farklı versiyonunu yayınlarsa, düğümler bunlardan herhangi birini alabilir. Böyle bir durumda düğümler seçtikleri zinciri kabul edip genişletmeye devam ederler. Ancak diğer bloğun da genişleme ihtimaline karşı bloğu kaydederler. Bu türde bir beraberlik bir sonraki iş kanıtında sonlanır. Bu durumda kısa zincirde kalan düğümler de uzun zincire geçerler.

Yeni işlem yayınlarının tüm düğümlere ulaşma zorunluluğu yoktur. Ulaşabildikleri kadar çok düğüme ulaştıkları sürece çok geçmeden bir bloğa dahil olurlar. Blok yayınları kayıp mesajlara toleranslıdır. Eğer ki düğüm bir bloğa bağlanmazsa, bir sonraki bloğu aldığı anda bloğu kaçırdığını fark eder ve talep eder.

Geleneksel bankacılık modelinde taraflara ve üçüncü partiye sınırlı bilgi paylaşımı yapılır. Tüm işlemlerin halka açık olması bu yöntemin kullanılamaz olmasına neden olur. Bu problem topluluk anahtarı anonim tutularak aşılabilir. Herkes herhangi birisinin bir başkasına ne kadar gönderdiğini görebilir ancak bunları ilişkilendiremez. Bu borsa piyasalarındaki işleyişe benzerdir.

Şekil 4: Gizlilik Modelleri



Kaynak: Nakamoto, 2008.

Ek güvenlik duvarı olarak, her işlemde anahtarın aynı kişiye bağlanmasını önlemek için yeni bir anahtar çifti kullanılmalıdır. Aynı sahipli çoklu girişlerde bu risk bulunmaktadır.

Korsan düğümlerin, doğru düğümlerden daha hızlı olduğu senaryo ele alındığında bu gerçekleşse bile düğümler geçersiz işlemi asla kabul etmeyecektir. Korsan kullanıcı yalnızca son harcadığı parayı geri değiştirmeyi deneyebilecektir.

Doğru zincir ve korsan zincirin arasındaki yarış Binomiyal Rassal Yürüyüş modeli ile karakterize edilebilir. Başarı durumu, doğru zincirin bir blok ile genişlemesidir, +1 ile genişler. Başarısızlık durumu korsan zincirin bir blok ile genişlemesidir, -1 ile azalır (Nakamoto, 2008).

1.1.4.2. Bitcoincash

Frankenfield (2018), Bitcoin mucidi Satoshi Nakamoto tarafından önerildiği gibi, Bitcoin'in günlük işlemler için kullanılan eşler arası bir kripto para birimi olması gerekmekte olduğunu, yıllar geçtikçe ve Bitcoin fiyatı yükseldikçe, Bitcoin bir para birimi yerine bir yatırım aracı haline geldiğini bildirmiştir. Blok zincirinin, artan işlem

sayısıyla başa çıkamadığı için ölçeklenebilirlik sorunlarıyla karşılaşmaya başladığını söylemiştir ki bu da Bitcoin'in blok zincirindeki bir işlem için onay süresi ve ücretleri artmıştır.

Frankenfield (2018) ayrıca Roger Ver gibi Bitcoincash'in başlıca savunucularının Bitcoin'in blok büyüklüğünde gerçekleşecek değişikliklerle Bitcoin'in günlük işlemler için bir araç olarak kullanılmasını sağlayacağını ve sınırların ötesinde işlemleri gerçekleştirmek için yüksek ücretler alan Visa gibi çok uluslu kredi kartı işleme kuruluşlarıyla rekabet etmesine yardımcı olacağını göstermiştir.

1.1.4.3. Ethereum

Ethereum ve Bitcoin birçok yönden benzerdir: her biri çevrimiçi borsalar aracılığıyla alınıp satılan ve çeşitli kripto para birimi cüzdanlarında saklanan dijital bir para birimidir. Bu göstergelerin her ikisi de merkezi olmayan, yani bir merkez bankası veya başka bir yetkili tarafından verilmediği veya düzenlenmediği anlamına gelir. Her ikisi de blok zinciri olarak bilinen dağıtılmış defter teknolojisini kullanır. Bununla birlikte, piyasa değerine göre en popüler iki kripto para birimi arasında birçok önemli fark vardır. Reiff (2020) aşağıda, Bitcoin ve Ethereum arasındaki benzerlikleri ve farklılıkları ele almıştır.

Bitcoin, herhangi bir hükümetin veya şirketin kontrolü dışında işleyen radikal olarak yeni bir dijital para biçiminin ortaya çıkışına işaret etmiştir. Zamanla insanlar, Bitcoin'in altında yatan yeniliklerden biri olan blok zincirinin başka amaçlar için kullanılabileceğini anlamaya başlamıştır.

Ethereum, blok zinciri teknolojisini yalnızca merkezi olmayan bir ödeme ağını sürdürmek için değil, aynı zamanda sahteciliğe karşı korumalı, merkezi olmayan finansal sözleşmeleri ve uygulamaları güçlendirmek için kullanılacak bilgisayar kodunu depolamak için kullanmayı önermiştir.

Ether, orijinal sitesinde Ethereum'un kullanıcının şahsi bankası olduğunu, güvenliğinin kriptografi tarafından sağlandığını, merkezi otoritesiz ve global olduğunu ve 18 basamağa kadar küçültülmüş Ether alınabildiğini bildirmektedir (www.ethereum.org, 2021).

1.1.4.4. Dash

2014 yılının Ocak ayında, Evan Duffield öncelikle Xcoin'i, ardından DarkCoin ve sonra günümüzdeki Dash kripto para birimini yaratmıştır.. Bitcoin ağındaki gizlilik

endişeleri nedeniyle yaratılan Dash, daha hızlı onaylarla son derece özel bir kripto para birimi olarak piyasaya girmiştir (Luz, 2019).

Zahar (2020), Dash'in dijital para olmayı amaçlayan, madencilikle yaratılan ve Bitcoin'e dayalı bir kripto para olarak tanımlamıştır ve Masternode işlevi, InstantSend ve PrivateSend olarak da bilinen iki katmanlı teşvik ağı gibi temel özellikleri içerdiğini belirtmiştir. Dash projesine ait bir ekip bulunmaktadır ve düzenli olarak yeni güncellemeler / gelişmeler gerçekleştirilmektedir. Dash dünya çapında birçok işletme tarafından kabul edilmektedir ve kullanım sayısı artmaktadır.

1.1.4.5. Decred

Garner (2019), Decred'i blok zincirinde merkezi olmayan yönetim ve karar almaya öncelik veren bir kripto para birimi olarak tanımlamıştır. Ayrıca doğrudan madenciler ve para sahipleri tarafından oylanan ve yürürlüğe giren iyileştirmelerle bağımsız olarak çalışan bir kripto para birimi olduğunu bildirmiştir ancak Decred, bu merkeziyetçi hedeflere ulaşmak için temel aldığı Bitcoin protokolünden bazı temel değişiklikleri içermektedir. Decred aynı zamanda bir ağ için merkeziyetçiliğin ve demokratik karar almanın en üst seviyesi olarak tanımlanmaktadır.

1.1.4.6. Nem

Seth (2019) ,NEM veya Yeni Ekonomi Hareketi'nin (New Economy Movement), daha akıllı ve teknolojik olarak daha gelişmiş bir blok zinciri geliştirmek amacıyla için Mart 2015'te bir başka popüler blockchain tabanlı sanal para birimi ve ödeme ağı platformu olan NXT'nin bir versiyonu olarak geliştiğini belirtmiştir.

Singapur merkezli, gelir amacı gütmeyen bir kuruluş olan NEM.io Foundation tarafından işletilmektedir. NEM, XEM adı verilen kendi kripto para birimine sahiptir. XEM, tüccarlar tarafından Bitcoin gibi bir ödeme aracı olarak kullanılmasa da, XEM yine de önemli ölçüde değer kazanmış ve şu anda en yüksek piyasa değerine sahip kripto para birimleri arasında ilk sıralarda bulunmaktadır.

1.1.4.7. Tether

Tether, diğer kripto paraların aksine sabit değerli olmasıyla dikkat çekmektedir. Tether, Bitcoin ve Ethereum gibi diğer popüler kripto para birimlerinin fiyatlarında gözlemlenen geniş dalgalanmaların aksine, kripto para birimi değerlemelerini sabit tutmayı amaçlayan, "stabilcoins" adı verilen yeni bir kripto para birimine aittir. Frankenfield (2019a), Tether'i özellikle itibari para birimleri ile kripto

para birimleri arasında gerekli köprüyü kurmak ve kullanıcılara istikrar, şeffaflık ve minimum işlem ücretleri sunmak için tasarlandığını bildirmiştir. Bununla birlikte, Tether Ltd. tarafından Tether'lerin gerçek parayla kullanılması veya takas edilmesi için herhangi bir garanti verilmemekte olduğunu; yani, Tether'in ABD doları ile takas edilemediğini söylemiştir.

1.1.4.8. VeChain

VeChain, tedarik zinciri yönetimini ve iş süreçlerini geliştirmek için tasarlanmış bir blok zinciri platformudur. Amacı, bu süreçleri ve karmaşık tedarik zincirleri için bilgi akışını dağıtılmış defter teknolojisi (DLT) kullanarak kolaylaştırmaktır. VeChain platformunun iki jetonu vardır: VeChain Token (VET) ve VeChainThor Energy (VTHO). İlki, VeChain'in ağında değer aktarmak için kullanılırken, ikincisi işlemleri güçlendirmek için enerji veya gaz olarak kullanılmaktadır (Frankenfield, 2019b).

1.1.4.9. Litecoin

Litecoin, çağdaşları gibi, bir anlamda bir çevrimiçi ödeme sistemi olarak işlev görür. PayPal veya bir bankanın çevrimiçi ağı gibi, kullanıcılar bunu birbirlerine para transferi yapmak için kullanabilmektedir. Ancak ABD doları kullanmak yerine işlemler Litecoin birimlerinde gerçekleştirmektedir. Litecoin'in çoğu geleneksel para birimi ve ödeme sistemiyle olan benzerliğinin bittiği yer burasıdır, ancak yine de Bitcoin dışındaki en önemli beş sanal para biriminden biridir.

Tüm kripto para birimleri gibi Litecoin de tarihsel olarak toplumun para basmak için güvendiği tek varlık olan bir hükümet tarafından çıkarılmamaktadır. Bunun yerine, bir Federal Rezerv tarafından düzenlenmesi ve Litecoin'lerin düşmesi, Litecoin işlemlerinin bir listesinin işlenmesinden oluşan madencilik adı verilen ayrıntılı bir prosedürle oluşturulmaktadır. Geleneksel para birimlerinin aksine, Litecoin arzı sabittir. Sonunda dolaşımda sadece 84 milyon Litecoin olacak ve bir tane daha olmayacak. Her 2,5 dakikada bir (Bitcoin için 10 dakikanın aksine), Litecoin ağı, dünya çapında son Litecoin işlemlerinin bir defter girişi olan blok adı verilen bir şey üretmektedir (Mcfarlane, 2019).

1.1.4.10. Ripple

Ripple ağının kripto para birimi XRP'dir ve Ripple'in ana özelliklerinden biri konsensüs defteridir. Değişim ağı ve ödeme protokolü San Francisco merkezli ABD

şirketi Ripple Labs tarafından oluşturulmuştur. Ripple ile Bitcoin arasındaki temel fark, Bitcoin üçüncü bir tarafa ihtiyaç duyulmadan kullanıcılar arasında alternatif bir ödeme sistemi olarak oluşturulurken, Ripple bankacılık sistemi için alternatif bir ödeme yöntemi olarak kurulmuş olmasıdır. Ripple'ın işlem süresi sadece 4 saniye sürerken ETH ve BTC süreleri genellikle 2 dakikadan 1 saate kadar sürebilmektedir (Zamboglou, 2018).

1.2. LİTERATÜR TARAMASI

Yayınlanan çeşitli çalışmalarda Bitcoin'in spekülasyon bir varlık olup olmadığı, diğer finansal kaynaklarla ilişkisi ve Bitcoin piyasası değerlendirilmiştir.

Blau (2018), çalışmada birkaç sentle işlem görmeye başlayan Bitcoin değerinin 2013 yılında 1.132,26 Amerikan dolarına ulaşmasından sonraki aylarda değerinin %60'ını kaybetmesinin varlık balonunun varlığını uygun şekilde temsil ettiğini belirtmiş ancak çalışmada yapılan testler sonucunda belirtilen dönemde spekülasyon ticaretin önemli ölçüde yaşanmadığı sonucuna varmıştır.

Çevik ve arkadaşları (2016), Bitcoin fiyatları, Bitcoin piyasası etkinliği, volatilitesi ve likiditesini değerlendirmiş, analiz sonucunda diğer para birimleri ile Bitcoin arasında anlamlı bir ilişki olmadığını ortaya koymuştur.

Atik ve diğerleri (2015), yaptıkları çalışma sonucunda 2009-2015 yılları arasındaki Bitcoin günlük kur fiyatı ile Japon yeni fiyatının birbirlerini gecikmeli olarak etkilediğini ve Japon yeninden Bitcoin'e doğru tek yönlü nedensellik ilişkisi olduğunu saptamıştır.

Bir diğer çalışmada, Ciaian ve arkadaşları (2018), kısa ve uzun vadeli dönem için Bitcoin ve altcoin piyasaları arasındaki fiyat bağımlılıklarını araştırmış ve altcoin fiyatlarının Bitcoin piyasasının gelişmesiyle yükseldiği hipotezi kısa dönem için reddedememişken uzun dönem için reddetmişlerdir. Bitcoin ve altcoin piyasasındaki fiyatlandırma benzerliklerinin piyasa ortaklıklarını güçlendirdiği hipotezini kısa dönem için tanımlayamamış fakat uzun dönem için reddetmişlerdir.

Tiwari ve arkadaşları (2018) yaptıkları çalışmada Bitcoin piyasasının Nisan-Ağustos 2013 ve Ağustos-Kasım 2016 dönemleri dışında etkin olduğunu bulmuşlardır.

Başka bir çalışmada Dwyer (2015), teknoloji kullanımı ve üretilen miktarın sınırlandırılmasının bir dijital paranın pozitif değere sahip olacağı, bir denge yaratabileceğini açıklamıştır. Bitcoin'in aylık getirilerinin volatilitésinin, altın veya

dolar gibi yabancı para birimlerinden daha yüksek olmasıyla birlikte Bitcoin için en düşük aylık dalgalanmaların yabancı para birimlerine göre en yüksek aylık dalgalanmalardan daha az olduğunu belirtmiştir.

Urquhart (2016) yaptığı çalışmada Bitcoin piyasasının incelenen dönem boyunca zayıf şekilde verimli olmadığını göstermiş ve incelediği 2. Dönemde bazı piyasa testleri için daha etkin hale gelebileceğini belirtmiştir.

Tekinay ve Deveci Kocakoç (2018) yayınladıkları bildiride Bitcoin'in altcoin, çeşitli para birimleri, borsa ve emtialarla olan eşbütünleşme ilişkisini incelemiştir. 2010-2018 yılları arasındaki verilere göre Bitcoin'in sadece altcoinlerden bazılarıyla koentegrasyon gösterdiğini bulmuşlardır.

Topaloğlu (2019), çalışmasında Bitcoin ve döviz kurları arasında uygulanan yapısal kırılmalı Gregory ve Hansen eşbütünleşme ve Granger nedensellik analizi sonuçlarına göre BTC/USD döviz kurundaki yapısal kırılmanın 2013 Nisan ve Aralık aylarında gerçekleştiğine ve Çin yuanı ve Bitcoin arasında tek yönlü pozitif nedensellik ilişkisi olduğu sonucuna ulaşmıştır.

Z. Chen ve arkadaşları (2020), yayınladıkları makalede makine öğrenimi tekniklerini kullanarak Bitcoin fiyatını farklı frekanslarda tahmin etmek için Bitcoin fiyatını günlük fiyata ve yüksek frekans fiyatına göre sınıflandırmışlardır. Yüksek boyutlu özelliklere sahip Bitcoin günlük fiyat tahmini için Lojistik Regresyon ve Doğrusal Ayrım Analizi gibi istatistiksel yöntemler, daha karmaşık makine öğrenme algoritmalarından daha iyi performans göstererek %66 doğruluk elde etmişlerdir. Günlük fiyat tahmini için kıyaslama sonuçlarıyla karşılaştırıldığında, istatistiksel yöntemlerin en yüksek doğruluğu ve sırasıyla %66 ve %65,3 olan makine öğrenimi algoritmaları ile daha iyi bir performans elde etmişlerdir.

Nakano ve diğerleri (2018), Bitcoin'in getiri tahmini için yapay sinir ağlarına dayalı derin öğrenme yöntemi kullanmışlardır. Uygulanabilir maliyet ayarları altında kullanılan yaklaşımın satın al ve tut stratejisini önemli ölçüde iyileştirdiğini göstermişlerdir. Kullanılan modelin özellikle Bitcoin için zorlu dönem olan Aralık 2017 ve Ocak 2018 aylarında oldukça iyi performans gösterdiğini belirtmişlerdir.

Silva de Souza ve arkadaşları (2019), yayınladıkları makalede makine öğrenimi tekniklerinin kripto para birimi fiyatlarının tahmininde nasıl performans gösterdiğini araştırmayı amaçlamıştır. Destek Vektör Makineleri (SVM) ve yapay

sinir ağı tabanlı stratejilerinin Bitcoin'e uygulanması durumunda anormal risk ayarlı getiriler oluşturup oluşturmayacağını yanıtlamışlardır.

Cavalli ve Amoretti (2020), çalışmalarında tek-boyutlu evrimsel sinir ağı (1D-CNN) modeline dayanan Bitcoin trend yaklaşımı göstermiştir. Uygulanan bu model ile uzun-kısa dönem hafızalı (LSTM) modellerine göre daha yüksek doğrulukta Bitcoin trend tahmini elde etmesine imkan tanıdığını belirtmiştir.

Alonso-Monsalve ve diğerleri (2020), yaptıkları çalışmada yüksek frekanslarda teknik analiz kullanarak kripto paraları döviz kurlarının trend sınıflandırılmasında geleneksel çok katmanlı algılayıcılara alternatif olarak evrimsel bileşenle sinir ağlarının uygunluğunu araştırmışlardır. Döviz kurlarından elde edilen 18 teknik göstereye göre tüm serilerin bir dereceye kadar öngörülebilir olduğunu göstermişlerdir. Evrimsel uzun-kısa dönem hafızalı sinir ağı önemli derecede öne çıkarken, evrimsel sinir ağı da özellikle Bitcoin, Ethereum ve Litecoin kripto para birimlerinde iyi sonuçlar verebilmiştir.

Lahmiri ve Bekiros (2019) , Bitcoin, Digital Cash ve Ripple gibi en popüler 3 dijital para biriminin fiyatlarını tahmin etmek için derin öğrenme tekniği uygulamıştır. Uzun-kısa hafızalı sinir ağı modellerinde doğrusal olmayan örüntü tanıma performansı yüksek olsa da kripto para piyasaları için derin öğrenme metodunun oldukça verimli olduğu sonucuna ulaşmışlardır.

Liu ve arkadaşları (2020) çalışmalarında Bitcoin'in fiyatını etkileyen 40 belirleyicili bir özellik sistemi oluşturduktan sonra Bitcoin fiyatını tahminlemek üzere derin öğrenme yöntemini kullanmışlardır. Elde edilen sonuçlarda hem yönlü hem de seviye tahmininde geri yayımlı sinir ağı ve destek vektör regresyon yöntemleri gibi popüler makine öğrenme yöntemlerine kıyasla daha iyi performans elde edildiği kaydetmişlerdir.

Lahmiri ve Bekiros (2020), başka bir çalışmada, Bitcoin fiyat serilerini tahminlemek için çok sayıda yapay zeka sistemini karşılaştırmalı olarak değerlendirmişlerdir. Elde ettikleri sonuçlar çift yönlü geri yayımlı sinir ağı (BRNN) modelinin tahminlerinde olağanüstü bir doğruluk sağlandığını ve yakınsamasının engellenmediğini ve oldukça hızlı olduğunu göstermişlerdir.

W. Chen ve diğerleri (2021) yayınladıkları makalede Bitcoin fiyatlarını tahminlemek için iki aşamalı yaklaşım geliştirmişlerdir. Elde ettikleri sonuçlara göre

ekonomi ve teknoloji belirleyicilerinden elde edilen bilgiler Bitcoin döviz kurunu tahmin etmek için oldukça önemlidir.

Jiang (2020) çalışmasında, Bitcoin'in dakika fiyatlarıyla ilgili veriler toplamış ve bunları saat cinsinden Bitcoin fiyatını yansıtacak şekilde yeniden düzenlemiştir. 24 saatlik veriyi girdi ve sonraki saati çıktı olarak almıştır. Çok Katmanlı Algılayıcı'nın (MLP) mevcut eğilime göre çok uygun olmadığını, Uzun-Kısa Dönem Hafıza Modeli (LSTM) ve Geçitli Tekrarlayan Ağ modelinin (Gated Recurrent Unit – GRU) dahil edildiğinde nispeten daha iyi sonuçlar elde edildiğini kaydetmiştir. Ele alınan bu çalışma ile tez sonuçları karşılaştırıldığında, 2 katmanlı Geçitli Tekrarlayan Ağ modeli ve 2 katmanlı Uzun-Kısa Dönem Hafıza modeli sonuçlarının en iyi performansı vermesi, Bitcoin fiyat tahminlerinde Uzun-Kısa Dönem Hafızalı modellerin etkili sonuçlar yaratabileceği sonucunu göstermektedir.

Ji ve arkadaşları (2019), yayınladıkları makalede Bitcoin fiyatlarını derin öğrenme yöntemiyle tahminlemeye çalışmışlardır. Sonuçlara göre Uzun-Kısa Dönem Hafızalı modellerin regresyon tahminlerine göre daha iyi sonuçlar verdiği ve derin öğrenme tabanlı modellerin fiyat artış ve düşüşlerinde iyi performans gösterdiği bildirilmiştir. Bu sonuçla birlikte Uzun-Kısa Dönem Hafızalı modellerin Bitcoin fiyat tahminlemelerinde etkili olduğu sonucu bir kez daha vurgulanmıştır.

Awoke ve diğerleri (2020), Bitcoin fiyat oynaklığını ele almak ve yüksek doğruluk için derin öğrenme tabanlı Uzun-Kısa Dönem Hafıza ve Geçitli Tekrarlayan Birim modellerini kullanmışlardır. Model performansları değerlendirildiğinde Geçitli Tekrarlayan Birim modelinin Uzun-Kısa Dönem Hafıza modeline göre daha iyi sonuç verdiği bulunmuştur. Elde edilen bu sonuca bakarak Bitcoin fiyat tahminlemesinde kullanılabilir derin öğrenme modelleri arasında Geçitli Tekrarlayan Birim ve Uzun-Kısa Hafıza modelleri düşünülebilmektedir.

Nobel ödüllü ekonomist Joseph Stiglitz, Bitcoin'in kara para aklama için kullanılmadığında Bitcoin'e talep kalmayacağı görüşünü bildirmiştir (Costa, 2018).

İKİNCİ BÖLÜM


ZAMAN SERİLERİ

2.1 ZAMAN SERİLERİ

Zaman serisi verileri normal verilerden farklı olarak zamana bağlı değişen gözlemlerden oluşur. Bu zaman dilimi yıllık, aylık, haftalık, günlük hatta saatlik bile olabilir. Zaman serisi analizlerinde veri çeşitli alanlarda incelenir. Bu incelendiği alanlar zaman serisi bileşenleri olarak bilinir ve çalışmada verinin bu bileşenlerinden ayrılması hedeflenir.

Zaman serisi bileşenleri 4 ana başlık altında incelenmektedir. Bunlar Şekil 5.'te Trend, Mevsimsellik, Döngü ve Konjonktürel Dalgalanma olarak ele alınmaktadır.


Şekil 5: Zaman Serisi Bileşenleri



2.1.1. Trend

Trend kelimesi İngilizce “Tendency” kelimesinden türemiştir ve “eğilim” anlamına gelir. Zaman serisi verilerinin genel eğilimi, uzun bir süre boyunca artma veya azalma yönündedir, uzun vadeli eğilim veya basit eğilim olarak adlandırılır. Ekonomi ve işletme ile ilgili zaman serilerinde gözlenen bu fenomen, örneğin ürünün miktarı, üretimi ve satışı vb. ile ilgili zaman serilerinde yükselme eğilimi bulunurken, ölümlerle ilgili zaman serilerinde düşüş eğilimi fark edilir. Şekil 6.'da trend eğilimi grafiği gösterilmektedir. Başlangıç noktasından bitiş noktasına kadar sürekli bir artış veya sürekli bir azalış gösteren grafikler için genel olarak artış eğiliminde veya azalış eğiliminde olduğu söylenir. Bu eğilim yeni teknoloji sonucu ortaya çıkan bir ürünün zamanla popülerleşip talebinin sürekli artması durumunda veya modası geçen bir eşyanın talebinin istikrarlı olarak düşüşünde gözlemlenebilir.

Şekil 6: Trend




Basit veya uzun vadeli eğilim olarak da adlandırılan eğilim, bir dizinin bir süre büyümeye veya azalmaya yönelik temel eğilimidir. Trend kavramı, kısa menzilli salınımları değil, daha çok uzun bir süre boyunca sabit hareketi içerir.

Doğrusal ve doğrusal olmayan trend bulunur. Tabloda çizilen zaman serisi verileri aşağı yukarı düz bir çizgiyi çevreliyorsa, doğrusal olarak adlandırılan zaman serileri tarafından sergilenen eğilim, aksi takdirde doğrusal olmayan eğilim olarak adlandırılır. Düz çizgi trendinde zaman serisi verileri sabit bir miktarda az ya da çok artar ya da azalır (Gulve, 2020).

2.1.2. Mevsimsellik

Birçok zaman serisi verileri mevsimsellik sergiler. Mevsimsellik, verilerin aylar veya mali yıllar gibi düzenli takvim aralıklarında yinelenen düzenli ve öngörülebilir değişiklikler yaşadığı bir zaman serisinin bileşenidir. Örneğin ilkbaharda diğer mevsimlere göre yazlık giysiler daha çok satılır ve tatil paketleri yaz aylarında okulun kapalı olduğu dönemlerde daha çok satılır. Benzer şekilde, kışları soğuk olan habitatlarda çok daha fazla kömür, doğalgaz vb. tüketilebilir. Sigorta endüstrisinde, zaman serisi verileri tropikal fırtınalara, orman yangınlarına ve dolu yağış fırtınalara duyarlı yerlerde devreye girmektedir. Borsa bu faktörlerin birçoğundan etkilenir ve aynı zamanda mevsimsellik gösterir (Strickland, 2015). Kış aylarında nezle ve grip salgınının artması, yaz aylarında azalması da zaman serilerindeki mevsimselliğin örneği olabilir.


Şekil 7: Mevsimsellik



2.1.3. Konjonktürel Dalgalanma

Konjonktürel dalgalanmalar da mevsimsellik etkisi gibi bir süre artış ardından azalış gösterir ve bu şekilde sürekli bir dalga oluşturacak halde hareket ederler. Ancak burada mevsimsellikten ayrılan önemli bir kısım vardır ki o da bu periyotların sabit değil düzensiz şekilde seyretmesidir. Bu ayırım yapılmazsa mevsimsellik etkisiyle karıştırılabilmektedirler (Erdem, 2020).

Şekil 8: Konjonktürel Dalgalanma



2.1.4. Düzensiz Hareketler

Bir zaman serisinin düzensiz bileşeni, eğilim döngüsü ve mevsimsel bileşenler (sezon etkileri dahil) kaldırıldıktan sonraki kalan zaman serisidir. Serinin yüksek frekans dalgalanmalarına karşılık gelir. Düzensiz bileşen, sistematik olmayan ve bazı durumlarda öngörülemeyen bir serideki kısa vadeli dalgalanmalardan kaynaklanır. Karakteristiği bulunmayan hava durumu modelleri örnek olarak gösterilebilir. Ancak önceden bazı düzensiz etkiler beklenebilir mesela katma değer vergisindeki

değişiklikler gibi. Oldukça düzensiz bir seride, bu dalgalanmalar hareketleri domine edebilir ve bu da eğilimi ve mevsimselliği maskeleyebilir (OECD, 2005).

Şekil 9: Düzensiz Etki



2.2. Durağanlık

Durağan bir zaman serisi, seri özelliklerinin serinin gözlemlendiği zamana bağlı olmayan seridir. Bu nedenle, trendleri olan veya mevsimsellik içeren zaman serileri durağan değildir çünkü trend ve mevsimsellik, zaman serilerinin değerini farklı zamanlarda etkileyecektir. Öte yandan, bir beyaz gürültü serisi durağandır (Hyndman ve Athanasopoulos, 2018).

Durağan olmayan veriler kural olarak öngörülemez, modellenemez veya tahmin edilemezdir. Durağan olmayan zaman serileri kullanılarak elde edilen sonuçlar, birinin bulunmadığı iki değişken arasındaki bir ilişkiyi göstermesi nedeniyle sahte olabilir. Tutarlı, güvenilir sonuçlar almak için, durağan olmayan verilerin durağan verilere dönüştürülmesi gerekir. Durağan süreç, sabit bir uzun vadeli ortalama etrafında döner ve zamandan bağımsız sabit bir varyansa sahiptir (Iordanova, 2020).

Eğer bir zaman serisi durağan değilse, aşağıda bahsedilen yöntemlerden bir tanesiyle durağanlığa dönüştürülmeye çalışılır.

Bunlardan ilki serinin gecikmesini almaktır. Bu gecikme 1'den fazla olabilecekse de 1 gecikme yeterlidir. Verilerde bir eğilim mevcut ise verilere bir tür eğri uydurulabilir ve bu uyumdan kalan kalıntılar modellenebilir. Uyumun amacı uzun vadeli eğimi basitçe ortadan kaldırmak olduğu için genellikle düz bir çizgi gibi basit bir uyum kullanılır. Sabit olmayan varyans için serinin logaritması veya karekökünü almak varyansı sabitleştirebilir. Negatif gözlem mevcutsa bunun engellenmesi için tüm gözlemler pozitif hale getirilir. Bunun için kullanılan sabit sonrasında tahmin

edilen deęerler ve gelecekteki noktaların tahmininin elde edilmesi için modelden çıkarılır. Mevsimsellik aynı zamanda duraęanlığı ihlal etse de genellikle zaman serisi modeline açıkça dahil edilir (Prins, 2012).

Duraęan olmayan bir serinin duraęan bir seriye dönüştürülmesinde fark alma yöntemi kullanılır. Verinin başladığı döneme t dönemi denir ve birinci gecikme alındığında buna birinci fark, ikinci gecikme alındığında ikinci fark olarak devam eder.

Düzey Deęeri: X_t

1. Fark: $X_t - X_{t-1}$

2. Fark: $X_t - X_{t-2}$

Düzey deęerlerinde duraęan seriye $I(0)$ veya 0. Dereceden entegre seri denir. Eęer seri 1. Farkında duraęanlaşıyorsa bu sefer ona $I(1)$ veya 1. Dereceden entegre seri denir. Duraęanlık serinin karakterini etkileyen çok önemli bir olgudur. Örneğin bir zaman serisinde “şok” olarak deęerlendirilebilecek beklenmedik bir deęişim sabit bir dizi için yavaşça yok olacaktır. Yani meydana gelen bu ani deęişimin etkisi zaman içinde daha küçük olacaktır. Genellikle duraęanlık testi için Dickey ve Fuller’in 1981 yılında yayınlanmış olan “Likelihood Ratio Statistics For Autoregressive Time Series With A Unit Root” isimli makalesinde formüle edilen genelleştirilmiş Augmented Dickey Fuller (ADF) teknięi kullanılmaktadır. (Mohamed, 2008).

Duraęan bir zaman serisi ortalaması, varyansı ve kovaryansıyla bulunduğu dönemle ilişkisi olmayan bağımsız bir seridir. Bu seriye kendi ortalaması etrafında hareketlerde bulunduğu için “ortalamaya dönüş” (mean reversion) da denir (Yalta, 2011).

2.3. Matematiksel Tahminleme

En başında matematiksel tahminleme kavramı basit olarak şans oyunları ile bağlantılı olarak ortaya çıkmıştır. Tahminlemenin temelini bir oyuncunun kazanmayı bekledięi miktar ile kazanma olasılıęının sonucu oluşturmuştur. Örnek olarak; toplamda 10.000 adet bilet bulunan ve büyük ödülün 4.800 ABD doları olduęu bir çekilişte matematiksel olarak bilet başına ödenecek beklenti $\frac{4.800\$}{10.000} = 0,48\$$ olarak hesaplanacaktır. İkinci ödül 1.200 ABD doları, üçüncü ödülün ise 400 ABD doları olduęunda 10.000 biletin toplamda $4.800\$ + 1.200\$ + 400\$ = 6.400\$$ veya ortalama olarak $\frac{6.400\$}{10.000} = 0,64\$$ olarak hesaplanacaktır. Farklı bir şekilde yorumlanırsa;

çekiliş birden çok kez tekrarlandığında, tekrarlanan zamanın %99,97'sinde veya 0,9997 olasılıkla kaybedileceği söylenebilir. Aynı şekilde her ödülün %0,01 veya 0,0001 olasılıkla kazanılabileceği söylenebilir. Ortalama olarak;

$$0(0,9997) + 4.800(0,0001) + 1.200(0,0001) + 400(0,0001) = 0,64\$$$

Bu, her miktarın karşılığı olan olasılıkla çarpımı sonucu elde edilen sonuç toplamıdır. Bu sonuç rastgele bir değişkendir ve beklenen değer olarak tanımlanır.

Rassal bir kesikli değişken olan X ve onun olasılık fonksiyonu $f(x)$ için beklenen değer;

$$E(X) = \sum_x x \cdot f(x) \quad (2.1)$$

Olarak tanımlanır. Eğer rassal değişken X sürekli bir değişken ise bu durumda onun olasılık yoğunluk fonksiyonu $f(x)$ aşağıdaki şekilde tanımlanır:

$$E(X) = \int_{-\infty}^{\infty} x \cdot f(x) dx \quad (2.2)$$

Bu tanımların geçerli olması için elbette ki toplam veya integralin olması gerekmektedir. Aksi takdirde tanımlar geçersiz sayılacaktır (Freund's, 2004).

2.4. Performans Ölçütleri

İstatistikler, elde edilen sonuçların alınan seçimler açısından önemli olup olmadığını ve ulaşılan sonuçların gerçekleştirdiğimiz deneylerle desteklenip desteklenmediğinin belirlenmesini sağlamaktadır. Öte yandan, sınıflandırıcıların performansı sadece sınıflandırma oranlarına göre verilmemektedir ve yeni doğruluk ölçülerinin önerilmesi veya uyarlanması konusunda artan bir ilgi vardır. Doğruluk ölçülerinin çoğu iki sınıflı problemler için önerilmiştir ve çok sınıflı problemlere adaptasyonları sezgisel değildir (García ve arkadaşları, 2009).

2.4.1. Ortalama

Ortalama, kesikli veriye sahip büyük veri setleri için tek merkez değeri olarak tanımlanır. Ortalamanın hesaplanması için gerekli formül aşağıda verilmiştir.

$$Ortalama = \sum_{i=1}^n \frac{x_i}{n} \quad (2.3)$$

Ortalama değeri, tüm verilerin toplamının veri sayısına bölümüyle bulunur. Formülde belirtilen 'n' değeri veri sayısıdır (Suhas, 2017).

2.4.2. Korelasyon

Korelasyon katsayısı aynı zamanda Pearson'ın Korelasyon Katsayısı olarak bilinmektedir. İki değişkenli Pearson Korelasyonu, sürekli değişken çiftleri arasındaki doğrusal ilişkilerin gücünü ve yönünü ölçen örnek bir korelasyon katsayısı ® üretir. Genel anlamda, Pearson Korelasyonu popülasyondaki aynı değişken çiftleri arasında bir popülasyon korelasyon katsayısı ρ ("rho") ile temsil edilen doğrusal bir ilişki için istatistiksel kanıt olup olmadığını değerlendirir. Pearson Korelasyonu parametrik bir ölçüdür. Matematiksel olarak aşağıdaki şekilde hesaplanır(Yeager, 2020).

$$r_{xy} = \frac{cov(x, y)}{\sqrt{var(x)} \cdot \sqrt{var(y)}} \quad (2.4)$$

2.4.3. Belirlilik Katsayısı

Belirlilik katsayısı, regresyon modeli ile açıklanabilen değerler içindeki değişkenlik yüzdesini ölçer. Bu nedenle %100'e yakın bir değer, modelin faydalı olduğunu ve sıfıra yakın bir değer modelin kullanışlı olmadığını gösterir.

Matematiksel olarak aşağıdaki şekilde gösterilebilir:

$$\Sigma(y_i - \bar{y})^2 = \Sigma(\hat{y} - \bar{y})^2 + \Sigma(y_i - \hat{y}_i)^2 \quad (2.5)$$

Yukarıdaki formülizasyon şu şekilde tanımlanabilir:

y değerindeki toplam değişkenlik = Model tarafından açıklanan değişkenlik + Açıklanamayan değişkenlik

$$R^2 = \frac{\text{modelde açıklanabilen sapma}}{\text{y değerlerindeki toplam sapma}} \quad (2.6)$$


R^2 , bağımsız değişken tarafında hesaplanan değerlerin toplam değişkenliğe oranını temsil eder. Basit doğrusal regresyon modellerinde, yani bir bağımsız değişken olan modellerde, $R^2 = r^2$ olduğu gösterilebilir. Burada r değeri X bağımlı değişkeni ile Y bağımsız değişken arasındaki korelasyon katsayısıdır (Eberly College of Science, 2021).

2.4.4. F-Testi

F dağılımı iki ayrı serbestlik derecesi olan m ve n'ye bağlıdır. Dağılım formülasyonu aşağıdaki gibidir:

$$f_{m,n}(F) = \frac{\Gamma\left(\frac{m+n}{2}\right) \left(\frac{m}{n}\right)^{\frac{m}{2}}}{\Gamma\left(\frac{m}{2}\right) \Gamma\left(\frac{n}{2}\right)} \frac{F^{\frac{m}{2}-1}}{\left(1 + \frac{mF}{2}\right)^{m+n/2}} \quad (F \geq 0) \quad (2.7)$$

Şekil 10: F-Dağılımı



Dağılım sıfırdan itibaren yükselir ve bazen serbestlik derecelerine bağlı olarak abartılı şekilde artış gösterir ve en yüksek noktaya ulaşır, ardından sağa çokça çarpık olacak şekilde düşüşe geçer. Şekil. 10'da %10, %5 ve %1 için Tablo gösterilmiştir.

F dağılımı genellikle 2 varyansın eşitliğinin tespitinde kullanılır. H_0 hipotezi $\sigma_{12} / \sigma_{22} = 1$, alternatif hipotez $\sigma_{12} / \sigma_{22} \neq 1$ olarak belirlenir. Test istatistiği $F = s_{12} / s_{22}$, s_1^2 ve s_2^2 , σ_1^2 ve σ_2^2 'nin istatistiksel bağımsız tahminçileridir. v_1 ve v_2 sırasıyla serbestlik dereceleridir. s_1^2 ve s_2^2 bağımsız ve normalse, $(s_1^2 / s_2^2) / (\sigma_{12} / \sigma_{22}) F(v_1, v_2)$ dağılımıdır. Eğer $\sigma_{12} = \sigma_{22}$ ise, $F = s_{12} / s_{22}$ de $F(v_1, v_2)$ dağılımıdır. Basit istatistiksel yaklaşımlarda bu test 2 kuyruklu (2-tailed) olarak anılır. Çünkü regresyon testleri her zaman F-istatistiğini en yüksek noktada “ s^2 çok büyük olabilir ama çok küçük olamaz” ve en dip noktada “ s^2 'nin σ^2 'yi çok iyi temsil ediyor” olarak alır. Başka bir deyişle, $H_0 = \sigma^{12} = \sigma^{22}$ ve $H_1 = \sigma^{12} > \sigma^{22}$ olduğu araştırılır (Draper ve Smith, 1998).

2.5. Koentegrasyon (Eşbütünleşme)

Koentegrasyon, eşbütünleşme, ekonometri tarihinin son çeyrek yüzyılında meydana gelmiş en önemli gelişmelerden bir tanesidir. Durağan olmayan $I(0)$ zaman serisi grubunun belirli bir doğrusal kombinasyonu durağan ise eşbütünleşme ilişkisine sahip olduğu söylenir. Bu konuda iki büyük yaklaşım vardır. Bunlardan bir tanesi 2 adımlı Engle-Granger metodu (Engle-Granger, 1987), diğeri Johansen Prosedürü'dür (Johansen, 1988) (Wang, 2009).

2.5.1. Engle-Granger Testi

Koentegrasyon veya eşbütünleşmenin varlığının sınanmasında yaygın kullanılan testlerden bir tanesi Engle-Granger testidir. Bu test değişkenlerin aynı seviyede durağan olduğunu varsayar. Eğer farklı seviyede durağan olduğu tespit edilen seri varsa o seriye önceki başlıklarda bahsedilen dönüşümlerden uygulanır böylece seriler arasındaki durağanlık seviyeleri eşitlenir. Aynı seviyede durağan hale getirilen serilerle yeni bir regresyon oluşturulur. Bu regresyonun kalıntıları düzey değerlerinde sınanır. Kalıntıların düzey değerindeki durağanlığı eşbütünleşmeyi doğrular.

$$Y_t = a_0 + a_1 X_t + u_{1t} \quad (2.8)$$

$$X_t = b_0 + b_1 Y_t + u_{2t} \quad (2.9)$$

Y_t ve X_t zaman serileri olmak üzere eşbütünleşme sınaması yapılacağında denklemlerinden bir tanesi kullanılarak regresyon kurulur ve hata terimi e_t elde edilir. Hata terimine birim kök testi uygulanır. Eğer hata teriminde birim kök bulunur ve hata teriminin durağan olmadığı sonucuna varılırsa seriler arasında koentegrasyon olmadığı sonucuna varılır. Ters olarak hata teriminde birim kök bulunmaz ve hata terimi durağan olarak belirlenir. Bu durumda iki serinin eşbütünleşik olduğu sonucuna varılır. Granger eşbütünleşik bulunan seriler için nedensellik testi ortaya koymuştur (Tarı, 2014).

2.5.2. Johansen Testi

Johansen eşbütünleşme testi, Engle-Granger eşbütünleşme testinin eksiklerinin giderilmesine yönelik ortaya çıkarılmış bir testtir. Johansen eşbütünleşme testinde, vektörlerin tahmini için En Çok Benzerlik yöntemi kullanılmaktadır.

Johansen testi, artırılmış DickeyFuller testinin çok değişkenli bir genellemesi olarak görülebilir. Genelleme olarak bahsedilen, birim kökler için değişkenlerin

doğrusal kombinasyonlarının incelenmesidir. Johansen testi ve tahmin stratejisi, ikiden fazla değişken olduğunda tüm eşbütünleşik vektörleri tahmin etmeye imkan verir. Her biri birim köklü üç değişken varsa, en fazla iki bütünleşen vektör vardır. Daha genel olarak, tümü birim köklere sahip n adet değişken varsa, en fazla n-1 adet eşbütünleşen vektör bulunmaktadır. Johansen testi, tüm eşbütünleşen vektörlerin tahmin edilmesini sağlar. Tıpkı Dickey-Fuller testinde olduğu gibi, birim köklerin varlığı standart asimptotik dağılımların geçerli olmadığını gösterir (Dwyer, 2015).

Johansen testi p adet Vektör Otoresgresyon Modeliyle (VAR) başlar.

$$y_t = \mu + A_1 y_{t-1} + \dots + A_p y_{t-p} + \varepsilon_t \quad (2.10)$$

y_t nx1 boyutlu genellikle 1. Dereceden durağan entegre değişken vektörü ve ε_t ise nx1 boyutlu değişkenlik vektörüdür. VAR modeli yeniden şu şekilde yazılabilir:

$$\Delta y_t = \mu + \Pi y_{t-1} + \sum_{i=1}^{p-1} \Gamma_i \Delta y_{t-i} + \varepsilon_t \quad (2.11)$$

$$\Pi = \sum_{i=1}^p A_i - I \text{ ve } \Gamma_i = - \sum_{k=i+1}^p A_k \quad (2.12)$$

Eğer katsayı matrisi Π 'nin azaltılmış rankı $r < n$ ise, o zaman $\Pi = \alpha\beta'$ ve $\beta'y_t$ durağan olacak şekilde her biri r ranklı nxr matrisleri α ve β vardır. R eşbütünleşme ilişkilerinin sayısıdır, α 'nın elemanları vektör hata düzeltme modelindeki ayarlama parametreleri olarak bilinir ve β 'nin her bir sütunu eşbütünleşme vektörüdür. Verilen bir r için, maksimum olasılık tahmincisi β 'nin, mevcut olduğunda gecikmeli farklılıklar ve deterministik değişkenler için düzeltildikten sonra Δy_t ile y_{t-1} 'in en büyük kanonik korelasyonunu veren y_{t-1} kombinasyonunu tanımladığı gösterilebilir (Hjalmarsson ve Österholm, 2010).

Johansen testinde 2 adet test bulunur. Bir tanesi İz (Trace) diğeri ise Maksimum test olarak hesaplanır. Johansen testinde adımlar şu şekildedir:

- 1- Model için otoresgresif k mertebesi araştırılır.
- 2- VAR modeli oluşturulup kalıntı vektörü elde edilir.
- 3- Ardından tekrar VAR modeli oluşturulup tekrar kalıntı vektörü bulunur.
- 4- Kalıntılardan özdeğer ve özvektörler aracılığıyla iki adet test istatistiği hesaplanır.
- 5- Test istatistikleri Johansen ve Juselius (1990) tablosuyla karşılaştırılır.
- 6- Test istatistiği > Kritik değer ise H_0 hipotezi reddedilir.

Hipotez testleri;

İz Testi için;

$$H_0 = r \leq r_0 \quad (2.13)$$

$$H_1 = r \geq r_0 + 1 \quad (2.14)$$

Maksimum Testi için;

$$H_0 = r = r_0 + 1 \quad (2.15)$$

olarak dikkate alınır (Tarı, 2014).

2.5.3. Vektör Otoregresyon Modeli

Vektör otoregresyon (VAR) modeli, çok değişkenli zaman serilerinin analizi için en başarılı, esnek ve kullanımı kolay modellerden biridir. Tek değişkenli otoregresif modelin dinamik çok değişkenli zaman serilerine doğal bir uzantısıdır. VAR modelinin ekonomik ve finansal zaman serilerinin dinamik davranışını açıklamak ve tahmin yapmak için özellikle yararlı olduğu kanıtlanmıştır. Genellikle tek değişkenli zaman serisi modellerinden ve ayrıntılı teori tabanlı eşzamanlı denklem modellerinden daha üstün tahminler sağlar. VAR modellerinden gelen tahminler oldukça esnektir çünkü modelde belirtilen değişkenlerin potansiyel gelecek yollarına koşullu yapılabilir (Zivot ve Jiahui, 2006).

Y ve X için basit VAR modeli şu şekilde yazılabilir:

$$X_t = a_{20} + \sum_{i=1}^p a_{21i} Y_{t-i} + \sum_{i=1}^p a_{22i} X_{t-i} + u_{2t} \quad (2.16)$$

$$Y_t = a_{10} + \sum_{i=1}^p a_{11i} Y_{t-i} + \sum_{i=1}^p a_{12i} X_{t-i} + u_{1t} \quad (2.17)$$

Burada bulunan α_{i0} sabit terimi, α_{ijk} ise i. Denklemden bulunan j. Değişkenin k gecikmesine ait parametreyi, u_{it} hata terimini ve p gecikme sayısını belirtir.

VAR modelinin aşamaları;

- 1- Değişkenler seçilir ve dışsaldan içsele doğru sıralanır.
- 2- Mertebelerin aynı dereceden olması şartı aranmadan durağanlık koşulu sağlanır.

- 3- Gecikme uzunlukları hesaplanır.
- 4- Analiz gerçekleştirilir ve yorumlanır (Tarı, 2014).

2.5.4. Granger Nedensellik Testi

Granger'in nedenselliği, regresyon denklemindeki geçmiş değerlerin katsayılarının sıfır olduğu şeklindeki boş hipotezini test eder. Daha basit bir ifadeyle, zaman serilerinin (x) geçmiş değerleri diğer serilere (y) neden olmaz. Bu nedenle, testten elde edilen p değeri 0,05 anlamlılık düzeyinden düşükse, sıfır hipotezini güvenle reddedilebilir (Maitra, 2019).

Granger Nedensellik testi hem x hem de y zaman serilerinin sabit olduğunu varsayar. Durum bu değilse, Granger Nedensellik testini kullanmadan önce ilk olarak farklılaştırma, trend azaltma veya diğer teknikler kullanılmalıdır.

Farklı m değerlerinin farklı test sonuçlarına yol açabileceği için gecikme sayısı, yani m'nin değeri kritiktir. M için uygun bir değer seçmeye yönelik bir yaklaşım, en küçük AIC (Akaike Bilgi Kriteri – Akaike Information Criteria) veya BIC (Bayesyen Bilgi Kriteri – Bayesian Information Criteria) değerine sahip tam modelle sonuçlanan değeri seçmektir.

Nedensellik sadece bir yönde veya her iki yönde olabilir (x, y'ye neden olur ve/veya y, x'e neden olur) veya her iki yönde de olmayabilir (Zaiants, 2021).

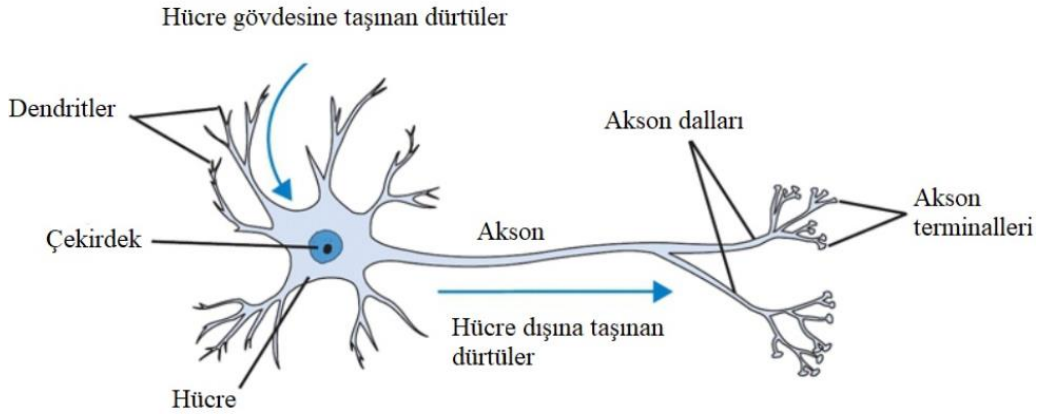
ÜÇÜNCÜ BÖLÜM

YAPAY SINİR AĞLARI VE DERİN ÖĞRENME


3.1. YAPAY SINİR AĞLARI

Sinir ağları ya da diğer bir deyişle yapay sinir ağları, insan beyninin bilgi işleyiş sürecinin temel düzeyde dijital bilgisayarın bilgi işleyiş sürecinden farklı olduğu varsayımıyla geliştirilmiştir. Nöronlar beynin temel yapıtaşı ve bilgi işleme modülüdür. Tipik bir beyinde muazzam miktarda (yaklaşık 10 milyon nöron kortekste ve bunlar arasında 60 trilyon bağlantı yani sinaps içerir) doğrusal olmayan ve paralel yapıda nöron bulunmaktadır. Sonuç olarak, insan beyni bilgiyi işleme, öğrenme ve muhakeme etme için çok verimli bir yapıya sahiptir (Montgomery ve diğerleri, 2012).

Şekil 10: Biyolojik Nöron Modeli



Şekil 11: Genelleştirilmiş Matematiksel Model



Kaynak: Fumo, 2017.


Yapay sinir ağı, araştırmacıların altta yatan fonksiyonları bilmediği karmaşık yapılar için uygun bir tür parametrik olmayan modelleme tekniğidir. Başka bir deyişle YSA, belirli işlev varsayımları olmaksızın verilerden öğrenebilir (Zhang, 2016).

Sinir ağı, bir sisteme yerleştirilmiş bir algoritmadır. Beynin bir işlevi yerine getirme şeklini modeller. Ağ, giriş parametrelerini simüle etmek ve en iyi çıktı çözümlerini üretmek için elektronik mekanizmalar kullanılarak veya yazılımda simüle edilen bir dijital bilgisayarda uygulanır. Bir sinir ağı, deneysel bilgileri depolamak ve bunlara çözüm sağlamak için doğal bir eğilime sahip olan basit işlem birimlerinden oluşan büyük ölçüde paralel dağıtılmış bir işlemcidir. Yapay sinir ağı, doğal beyne iki şekilde benzer:

i. İlk gözlem ve benzerlik, bilginin edinilmesi ve depolanmasıyla ilgilidir. Ağ, çevresinden bir öğrenme süreci yoluyla bilgi edinebilir.

ii. Sinir ağının doğal beyne benzemesinin ikinci yolu, nöronların birbirine bağlanmasıyla ilgilidir. Nöronlar, çok yönlü bir modelde takviye edilir, güçlendirilir ve iç içe geçer. Bir sinir ağında öğrenme sürecini yürütmek için kullanılan teknik, istenen bir hedefe ulaşmak için ağın sinaptik ağırlıklarını düzenli bir şekilde değiştirme görevi olan bir öğrenme algoritması olarak adlandırılır (Okwu ve Tartibu, 2021).

Şekil 12: Yapay Sinir Ağı Kategorileri



Kaynak: Abiodun ve arkadaşları, 2018.

3.1.1. Yapay Sinir Ağı Terminolojisi

İşlem Birimi: Yapay sinir ağları (YSA), biyolojik sinir ağ yapısının basitleştirilmiş modeli olarak düşünülebilir. Yapay sinir ağları birbirlerine bağlı işlem birimlerinden meydana gelir. Genel bir işlem birimi toplama bölümü ve çıktı bölümü olmak üzere 2 bölümden oluşur. Toplama bölümü n adet girdi değerini alır, her birini ağırlıklandırır ve ağırlıklandığı değerleri toplar. Ağırlıklandırılmış toplam aktivasyon değeri olarak tanımlanır. Her bir değer ağırlık işareti girdinin pozitif veya

negatif ağırlık olup olmadığını belirler. Girdiler kesikli veya sürekli değer olabildikleri gibi çıktı değeri de kesikli veya sürekli olabilir. Girdi ve çıktı, problem ve onun çözümünün doğasına uygun şekilde deterministik, stokastik veya bulanık olarak ele alınabilir.

Bağlantılar: Yapay bir sinir ağında, bir örüntü tanıma görevini gerçekleştirmek için bazı yapılara göre birkaç işlem birimi birbirine bağlanır. Bu nedenle bir işlem biriminin girdileri diğer işlem birimlerinin çıktularından ve/veya bir dış kaynaktan gelebilir. Her bir bölümün çıktısı kendisi dahil birkaç bölüme verilebilir. Başka bir birim tarafından alınan bir birimin çıktısının miktarı, birimler arasındaki bağlantının gücüne bağlıdır ve bağlantının ilişkili ağırlık değerine yansıtılır. Belirli bir YSA'da n birim varsa, o zaman herhangi bir anda her birimin benzersiz bir aktivasyon değeri ve benzersiz bir çıktı değeri olacaktır. Ağın n aktivasyon değerlerinin kümesi, o anda ağın aktivasyon durumunu tanımlar. Benzer şekilde, ağın n çıktı değerlerinin kümesi, ağın o andaki çıktı durumunu tanımlar. Aktivasyon ve çıktı değerlerinin kesikli veya sürekli doğasına bağlı olarak, ağın durumu, kesikli veya sürekli bir n boyutlu uzaydaki bir nokta ile tanımlanabilir.

İşlemler: Çalışma sırasında, bir YSA'nın her birimi diğer bağlı birimlerden ve/veya harici bir kaynaktan girişler alır. Belirli bir anda girdilerin ağırlıklı toplamı hesaplanır. Ortaya çıkan aktivasyon değeri, çıktı fonksiyonu biriminden gerçek çıktıyı, yani birimin çıktı durumunu belirler. Çıkış değerleri ve diğer harici girişler, diğer birimlerin aktivasyon ve çıkış durumlarını belirler. Ağın birimlerinin aktivasyon değerleri (aktivasyon durumu) zamanın bir fonksiyonu olarak aktivasyon dinamikleri olarak adlandırılır. Aktivasyon dinamikleri ayrıca ağın çıkış durumunun dinamiklerini de belirler. Tüm aktivasyon durumları kümesi, ağın durum uzayını tanımlar. Tüm çıktılarının kümesi durumlar, ağın çıkış veya sinyal durum uzayını tanımlar. Aktivasyon dinamikleri, ağın durum uzayındaki durumların yolunun yörüngesini belirler (Yegnanarayana, 1994).

Aktivasyon / Başlangıç Fonksiyonu: Bir nöronun zamanla değişen değer çıktısıdır. Bir aktivasyon fonksiyonunda dikkate alınması gereken en önemli şey eşik bazlı sınıflandırıcıdır (threshold based classifier). Eşik bazlı sınıflandırıcı, doğrusal dönüşümün değerinin nöronu aktive etmesinin gerekip gerekmediğini gösterir. Aktivasyon fonksiyonunun girişi bir eşik değerinden büyükse bir nöronun aktive

olduğu veya devre dışı bırakıldığı söylenebilir. Böyle bir durumda elde edilen çıktı bir sonraki katmanın girdisi olamaz (Siddharth Sharma ve arkadaşları, 2020). Çok sayıda kullanılan aktivasyon fonksiyonu vardır. Bunlardan en çok kullanılan 5 tanesi açıklanmıştır.

i) İkili Adım (Binary Step Function):

İkili adım fonksiyonu kullanılan en basit aktivasyon fonksiyonudur. İkili sınıflandırıcı oluştururken genelde ikili aktivasyon fonksiyonu kullanılır. Ancak çok sınıflı bir durumda ikili adım işlevi kullanılamaz. Ayrıca ikili adım fonksiyonunun gradyanı sıfırdır ve geri yayılımda engel yaratabilir. Yani $f(x)$ fonksiyonu türevi x 'e göre hesaplanırsa sonuç sıfıra eşit olacaktır. Matematiksel olarak aşağıdaki şekilde gösterilebilir (Siddharth Sharma ve arkadaşları, 2020):

$$f(x) = 1, \quad x \geq 0 \quad (3.1)$$

$$f(x) = 0, \quad x < 0 \quad (3.2)$$

ii) Doğrusal Aktivasyon Fonksiyonu:

Doğrusal aktivasyon fonksiyonu girdiyle doğru orantılıdır. İkili adım fonksiyonunun ana dezavantajı x 'in bileşeni olmadığı için sıfır gradyan olmasıdır. Bunu ortadan kaldırmak için doğrusal fonksiyon kullanılabilir. Şu şekilde tanımlanabilir:

$$f(x) = ax \quad (3.3)$$

a değişkeninin değeri, kullanıcı tarafından seçilen herhangi bir sabit değer olabilir (Siddharth Sharma ve arkadaşları, 2020).

Temel olarak sinir ağı işlemi, ağırlıklandırılmış girdi sinyallerini toplayıp bunu çıktı ya da aktivasyon fonksiyonu olarak uygulamayı içerir. Bu işlevi girdi birimleri için doğrusal fonksiyon yapar. Tipik olarak, gerekli olmasa bile aynı aktivasyon fonksiyonu her katmanda ve her nöron için uygulanabilir. Çoğu durumda doğrusal olmayan aktivasyon fonksiyonları kullanılır. Tek katmanlı ağlarla karşılaştırıldığında, çok katmanlı ağların avantajlarının kullanılabilmesi için doğrusal olmayan fonksiyonların kullanılması gerekir (Fausett Laurene, 1994).

iii) Sigmoid Aktivasyon Fonksiyonu:

Sigmoid fonksiyonu gerçek değerli bir sayıyı 0 ile 1 arasındaki aralığa sıkıştırır. Özellikle büyük negatif sayılar 0'a, büyük pozitif sayılar ise 1'e dönüştürülür. Sigmoid işlevi geçmişte çok kez kullanılmıştır çünkü bir nöronun

harekete geçme hızı olarak, 0 yani hiç harekete geçmeme ve 1 varsayılan maksimum bir frekansta tamamen harekete geçme olarak yorumu vardır. Uygulamada sigmoid fonksiyonunun doğrusal olmama durumu son dönemde bu fonksiyonun kullanımını azaltmıştır ve günümüzde nadiren kullanılmaktadır. İki büyük dezavantajı vardır ve bunlar şu şekilde sıralanabilir: Sigmoidler gradyanları yutar ve yok eder ve sigmoid çıktıları sıfır merkezli değildir. Sigmoid aktivasyon fonksiyonu matematiksel olarak aşağıdaki şekilde tanımlanır (Stanford University, 2020):

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (3.4)$$

iv) Tanh Aktivasyon Fonksiyonu:

Tanh aktivasyon fonksiyonu, Hiperbolik Tanjant Aktivasyon Fonksiyonu olarak da bilinir. Tanh aktivasyon fonksiyonunun aralığı -1 ile 1 arasındadır ve s şeklinde grafiği vardır. Bunun avantajı, negatif girdiler güçlü bir şekilde negatif olarak eşlenir ve sıfır girdiler tanh grafiğinde sıfıra yakın bir şekilde eşlenir. Ayrıca fonksiyonun türevlenebilir ve monoton olması ancak türevinin monoton olmaması avantajları arasında gösterilebilir (Sagar Sharma, 2017).

v) ReLU:

Düzeltilmiş Lineer Aktivasyon Fonksiyonu veya kısaca ReLU (Rectified Linear Activation Function) birçok sinir ağı türü için varsayılan aktivasyon fonksiyonu haline gelmiştir çünkü onu kullanan bir modelin eğitilmesi daha kolaydır ve genellikle daha iyi performans elde eder (Brownlee, 2019a). Ancak bu fonksiyondaki sorun tüm negatif değerlerin anında sıfıra eşitlenmesidir ki bu da modelin verilere uyma veya eğitilme yeteneğini azaltır. Böylece negatif girdiler uygun şekilde eşlenmediği için sonuç grafiği etkilenir (Sagar Sharma, 2017).

Geri yayılım (Genelleştirilmiş Delta Kuralı): Algılayıcı (perceptron) sinir ağının bir dizi girdi modeline iyi sonuçlar üretmek için “eğitildiği” işleme verilen bir ad. Bunun ışığında, Algılayıcı ağına bazen “destek ağı” adı verilir.

Net Girdi / Eğilim: Bir nöronun harekete geçmesi için nöral aktivasyonların aşması gereken miktarla orantılıdır.

Bağlantılık: Bir sistemdeki etkileşim miktarı, sinir ağındaki ağırlıkların yapısı veya bir tablodaki ilişkili kenar sayısıdır.

Örüntü Tanıma: Önceden öğrenilmiş veriyle örüntüleri tanıma eylemidir. Bu, sinir ağı gürültülü olsa veya sinir ağının bazı verileri eksik olsa dahi gerçekleştirilebilir.

Dönem: Ağ eğitimi sırasında bir eğitim setinin tamamlanmış çıktı süresidir.

Girdi Katmanı: Dış kaynaktan beslenen girdi nöronlarıdır.

Eğitim Algoritmaları (Danışmanlı/Danışmansız): Sinapsların, sinir ağı ağırlıklarının ya da diğer değiştirilebilir parametrelerin otomatik olarak ayarlanıp hedefe daha kolay ulaşılabilir olmasını sağlayan adaptasyon sürecidir. Geri yayımlı algoritma örnek olarak gösterilebilir.

Eğitim Kuralı: Eğitim sırasında eğitim modelindeki bağlantı yükü ya da ağırlığını değiştirmek için kullanılan algoritmadır.

Katman: Belirli bir işleve sahip ve bütün olarak işlem gören bir grup nörondur. En yaygın bilineni giriş, çıkış ve bir veya daha fazla ara katmana sahip ileri beslemeli bir ağ modelidir.

Monte-Carlo Metodu: Monte-Carlo yöntemi bilgisayarda çeşitli matematiksel problemlere istatistiksel örnekleme yöntemleriyle yaklaşık sonuçlar sağlar.

Çok Katmanlı Algılayıcı (MLP): En az 1 gizli katmanı bulunan bir çeşit ileri beslemeli sinir ağı türüdür. Katmanlar girişten başlayıp çıkışa kadar güncellenerek devam eder. Her nöron, net bir girdi elde etmek için gelen sinyallerin ağırlıklı bir toplamını hesaplar ve nöronun aktivasyon değerini vermek için bu değeri sigmoidal aktivasyon fonksiyonundan geçirir. Algılayıcıdan farklı olarak MLP doğrusal olmayan problemleri çözebilir.

Sinir Ağı: Sinaps veya ağırlıklarla birbirine bağlanan nöron ağıdır. Her nöron, kendisine bağlı olan nöronların aktivasyonlarının bir işlevi olan basit bir hesaplama yapar. Geri besleme mekanizmaları ve/veya nöronların doğrusal olmayan çıktı tepkisi yoluyla ağı bir bütün olarak evrensel hesaplama ve evrensel yaklaşım dahil olmak üzere son derece karmaşık görevleri yerine getirebilir. İleri beslemeli, geri beslemeli ve tekrarlayan sinir ağı olmak üzere 3 farklı türü bulunur ve sahip oldukları bağlantı derecesi ve türüne göre değişkenlik gösterir.

Nöron: Gelen sinyaller üzerinde ağırlıklı bir toplam gerçekleştiren, net bir girdi elde etmek için bu değere bir eşik veya yanlılık terimi ekleyen ve bu son değeri

kendi aktivasyonunu hesaplamak için bir aktivasyon fonksiyonu aracılığıyla eşleyen basit bir hesaplama birimidir. Geri bildirimde veya Hopfield ağlarında bulunanlar gibi bazı nöronlar önceki aktivasyonların bir kısmını koruyacaktır.

Çıktı Nöronu: Çıktıları ağın sonucu olan ağ içindeki nörondur.

Algılayıcı: Basit örüntü tanıma ve sınıflandırma görevini yapan yapay sinir ağıdır. Sinyallerin giriş, ardından gizli katmana ve çıktı katmanına ilerlediği ağları ağıdır. Katman içinde bağlantı yoktur.

Sigmoid Fonksiyonu: Genellikle bir sinir ağında aktivasyon işlevi olarak kullanılan S şekilli işlevdir.

Eşik Değer: Nöronun net girdisini oluşturan, bir nörona ağırlıklı girdilerin toplandığı veya çıkartıldığı bir miktardır. Sezgisel olarak net girdi bir nöronun harekete geçmesi gereken nöral aktivasyonların aşılması gereken miktarla orantılıdır.

Eğitim Seti: Bir sinir ağı bir eğitim seti kullanılarak eğitilir. Eğitim seti, girdi uyarımı olarak çözülmesi gereken problem hakkındaki bilgileri içerir. Bazı bilgisayarlarda eğitim seti “gerçekler” olarak adlandırılır.

Ağırlık: Sinir ağında, iki nöron arasındaki bağlantının gücüdür. Ağırlıklar pozitif/destekleyici veya negatif/engelleyici olabilir. Bir nöronun eşiği, bir öğrenme algoritması tarafından adaptasyona tabii tutuldukları için ağırlık olarak da kabul edilir (European Space Agency, 2021).

3.1.2. Yapay Sinir Ağı Sınırlamaları

Herhangi bir teknik gibi, sinir ağlarının da bazı dezavantajları vardır ve bunlar yazarların tahmin amacıyla YSA’yı seçme konusunda eğitilmiş bir karar vermelerini sağlamak için vurgulanmıştır.

- i. Sinir ağı bir çözümün genel bir yaklaşımını bulduğundan, genellikle tüm sinir ağı çıktılarıyla ilişkili küçük bir hata vardır.
- ii. Sinir ağlarının tam doğası hala tam olarak anlaşılammıştır ve bu nedenle mevcut araştırmalar performans sorununa deneysel bir yaklaşım benimsemelidir.
- iii. Şu anda, makul bir maliyetle temin edilebilen herhangi bir sinir ağı bilgisayarı bulunmamaktadır.
- iv. Yapay sinir ağı hataları mimariye bağlı olarak değişir.
- v. Sinir ağları uzun eğitim süreleri gerektirir (Majumder, 2015).

3.1.3. Yapay Sinir Ağının Avantajları

- i. Uyarlanabilir Öğrenme: Eğitim veya ilk deneyim için verilen verilere dayalı olarak görevlerin nasıl yapılacağını öğrenme yeteneği mevcuttur.
- ii. Kendiliğinden Organizasyon Yapma Yeteneği: Bir YSA kendi organizasyonunu veya öğrenme süresi boyunca aldığı bilginin temsilini oluşturabilir.
- iii. Gerçek Zamanlı Çalışma: YSA hesaplamaları paralel olarak gerçekleştirilebilir ve bu kabiliyetten yararlanan özel donanım cihazları tasarlanıp üretilmektedir.
- iv. Örüntü Tanıma: verilerdeki bilgileri kullanmak ve onu genellemek için güçlü bir tekniktir. Sinir ağları, veri setinde bulunan kalıpları tanımayı öğrenir.
- v. Sistem programlama yerine öğrenme yoluyla geliştirilir. Sinir ağları, analisti daha ilginç işler için özgür kılarak, verilerdeki kalıpları kendilerine öğretir.
- vi. Sinir ağları değişen ortamda esnekler. Sinir ağlarının ani bir köklü değişikliği öğrenmesi biraz zaman alsa da sürekli değişen bilgilere uyum sağlamada mükemmeldirler.
- vii. Yapay sinir ağları, geleneksel yaklaşımlar başarısız olduğunda bilgilendirici modeller oluşturabilir. Sinir ağları çok karmaşık etkileşimleri idare edebildiği için, çıkarımsal istatistikler veya programlama mantığı gibi geleneksel yaklaşımlarla modellemesi çok zor olan verileri kolayca modelleyebilirler.
- viii. Sinir ağlarının performansı en azından klasik istatistiksel modelleme kadar iyidir ve çoğu problemde daha iyidir. Sinir ağları, önemli ölçüde daha kısa sürede verilerin yapısını daha iyi yansıtan modeller oluşturur (Maind ve Wankar, 2014).

3.1.4. Yapay Sinir Ağlarının Ana Yapısı

Genel olarak incelendiğinde yapay sinir ağları 3 bölümde incelenebilir. Bunlar Girdi Katmanı, Gizli/Ara/Orta Katman, Çıktı Katmanı olarak adlandırılır.

3.1.4.1. Girdi Katmanı

Girdi katman, dış ortamdan bilgi (veri), sinyal, özellik veya ölçüm almaktan sorumludur. Bu girdiler (örnekler veya modeller) genellikle aktivasyon fonksiyonları tarafından üretilen sınır değerler dahilinde normalleştirilir. Bu normalleştirme ağ tarafından gerçekleştirilen matematiksel işlemler için daha iyi sayısal hassasiyetle sonuçlanır (Silva ve arkadaşları, 2017).

3.1.4.2. Gizli Katman

Gizli katman, girdi değerlerinin ağırlıklı toplamlarının hesaplanıp net aktivasyonu oluşturur. Net aktivasyon, gizli katmandaki ağırlıkların girdi değerleriyle çarpımıdır. Matematiksel olarak aşağıdaki şekilde gösterilebilir:

$$net_j = \sum_{i=1}^d x_i w_{ji} + w_0 = \sum_{i=1}^d x_i w_{ji} \equiv w_j^T x \quad (3.5)$$

Yukarıda belirtilen denklemde i indeksi girdi katmanındaki her bir girdiyi, j indeksi gizli katmandaki her bir girdiyi, w_{ji} ise gizli katmandaki girdi değerinin ağırlığını gösterir. Her bir gizli katman kendi aktivasyonunun doğrusal olmayan fonksiyonu olan bir çıktı belirtir (Çelebi, 2020).

3.1.4.3. Çıktı Katmanı

Çıktı katmanı aynı zamanda nöronlardan oluştuğu için önceki katmanlarda gerçekleştirilen işlemlerden ortaya çıkan nihai ağ çıktıları üretmekten sorumludur. Sinir ağlarının ana mimarisi ve nöron düzeninin yanı sıra bunların birbirlerine nasıl bağlandığı ve katmanların nasıl oluşturulduğu dikkate alınırsa 3 başlıkta incelenebilirler. Bunlardan ilki tek katmanlı ileri beslemeli ağlar, ikincisi çok katmanlı ileri beslemeli ağlar ve diğeri tekrarlayan ağlar olmak üzere sonraki başlıkta incelenmiştir (Silva ve arkadaşları, 2017).

3.2. YAPAY SİNİR AĞI ÖĞRENME YAPILARI

Yapay sinir ağlarının eğitim stratejilerinde 2 tip öğrenme çeşidi bulunmaktadır. Bunlardan bir tanesi denetimli diğeri ise denetimsiz öğrenmedir. Sonraki başlıklarda bu öğrenme tiplerinden bahsedilecektir.

3.2.1. Denetimli Öğrenme

Denetimli öğrenme stratejisi, belirli bir dizi girdi sinyali için istenen çıktıların mevcut olmasından oluşur. Diğeri bir deyişle, her eğitim örneği giriş sinyallerinden ve

buna karşılık gelen çıktılardan oluşur. Bundan dolayıdır ki süreci ve davranışını temsil eden davranış/değer tablosu olarak da tanımlanan girdi/çıktı verilerinin eklendiği bir tablo oluşturulur. Bu bilgiyle sinir ağları hakkında öğrenilen sistem hakkında hipotez oluşturulur (Silva ve arkadaşları, 2017).

3.2.2. Denetimsiz Öğrenme

Denetimsiz sinir ağları verilerin yaklaşık değerlerinin sunulduğu algoritmalarıdır. Aşağıdaki şekilde bir işlevi vardır:

$$x' = f(x, w) \quad (3.6)$$

Burada x girdi vektörü, w , yaklaşık veya herhangi başka bir fonksiyonun ağırlığı, x' ise başka bir uzayda giriş vektörünün izdüşümüdür (Buscema ve arkadaşları, 2018).

Ağa sadece giriş verilerinin verildiği bir eğitim şemasıdır. Ağ veri setinin bazı özelliklerini öğrenir ve bu özellikleri çıktılara yansıtmayı öğrenir. Örneğin ağ verilerin bazı sıkıştırılmış temsillerini öğrenir. Bu tür bir öğrenme, biyolojik olarak daha makul bir öğrenme modeli sunar (Majumder, 2015).

3.3. YAPAY SİNİR AĞLARINDA ÖĞRENME KURALLARI

Yapay sinir ağlarında çok fazla çeşit öğrenme kuralı bulunmaktadır. En sık kullanılan öğrenme kuralları derlenerek sonraki başlıklarda açıklanmıştır.

3.3.1. Hopfield Öğrenme Kuralı

Bu öğrenme kuralı bazı ilginç özelliklere sahiptir. Bunlar;

- Bir matriste bir dizi girdi/çıktı ilişkisini saklayabilir.
- Benzer ancak özdeş olmayan girdi kalıplarını tanıyarak ve aynı çıktı modelini üreterek bir dereceye kadar genelleme yapabilir.
- Önceki özellikle birlikte eksik veya bozuk giriş modellerinden doğru çıktı üretme yeteneğine sahiptir.

Bunlarla birlikte doğrusal olmayan ayrıştırılabilir işlevleri temsil edememesi tek katmanlı ağlarla aynı dezavantajlara sahip olmasına neden olur (Picton, 1994).

3.3.2. Boltzmann Öğrenme Kuralı

Boltzmann öğrenme kuralı mimarisinde her birim diğer tüm birimlere bağlanan bir dizi işlem biriminden oluşur. Birimlerin sayısı tipik olarak girdi modeli boyutundan daha büyüktür. Ek birimlere gizli birimler denir. Gizli birimlerin kullanılması tam

olarak bağı bir ağ tarafından desen depolamanın zor sorunlarının üstesinden gelmeye yardımcı olur. Modeller görünür birimlere (girdi ve çıktı birimleri) uygulanır ve görünür birimlerin sayısı girdi modellerinin boyutuna eşittir (Yegnanarayana, 1994).

3.3.3. Hebbian Öğrenme Kuralı

Bir sinir ağı için en eski ve en basit öğrenme kuralı genellikle Hebb kuralı olarak bilinir. Hebb, öğrenmenin, sinaps ağırlıklarının, birbirine bağı iki nöronun her ikisi de aynı anda “açık” olması durumunda bu nöronlar arasındaki ağırlığın artırılmasıyla gerçekleştiğini öne sürmüştür. Orijinal ifadede sadece aynı anda harekete geçen nöronlardan bahsedilmektedir. Bununla birlikte her iki nöron aynı anda “kapalı” ise ağırlıkların arttırılması durumunda daha güçlü bir öğrenme şekli ortaya çıkarmaktadır (Fausett Laurene, 1994).

3.3.4. Kohonen Öğrenme Kuralı

Bir Kohonen ağına amacı, daha önce olduğu gibi, ağırlıkları ayarlamak için Kohonen öğrenimini kullanarak kendi kendini organize eden bir model sınıflandırıcı üretmektir. Tipik olarak, bir Kohonen ağı iki boyutlu bir nöron dizisinden oluşur ve tüm girdiler tüm nöronlara ulaşır. Her nöronun örnek bir model olarak kabul edilebilecek kendi ağırlıkları vardır. Ağa bir girdi örüntüsü ulaştığında, girdi örüntüsüne en çok benzeyen örnek düzene sahip nöron en büyük tepkiyi verecektir. (Picton, 1994).

3.4. TEK KATMANLI SİNİR AĞI

Tek katmanlı sinir ağı yapısında bir adet bağlantı ağırlığı katmanı bulunur. Genellikle, girdi birimi dış kaynaktan veriyi alan ve çıktı birimi sonuç çıktısını veren birim olarak tanımlanır. Girdi birimleri tüm çıktı birimlerine bağıdır ve tüm çıktı birimleri diğere çıktı birimleriyle ilişkisizdir. Karşit olarak, Hopfield ağ mimarisinde tek katmanlı ağ yapısında her birim fonksiyonu hem girdi hem çıktı birimidir (Fausett Laurene, 1994).

Tek katmanlı sinir ağıları, bir sinir ağı organizasyonunun en basit durumunu temsil eder; giriş katmanı doğrudan çıkış nöron katmanına bağılanır. Tek katmanlı olarak adlandırılırlar çünkü yalnızca bir hesaplama düğüm katmanına sahiptirler (Rios ve arkadaşları, 2020).

Tek katmanlı ağ mimarileri içerisinde en popüler İleri Beslemeli Ağlar aşığıdaki şekilde açıklanabilir:

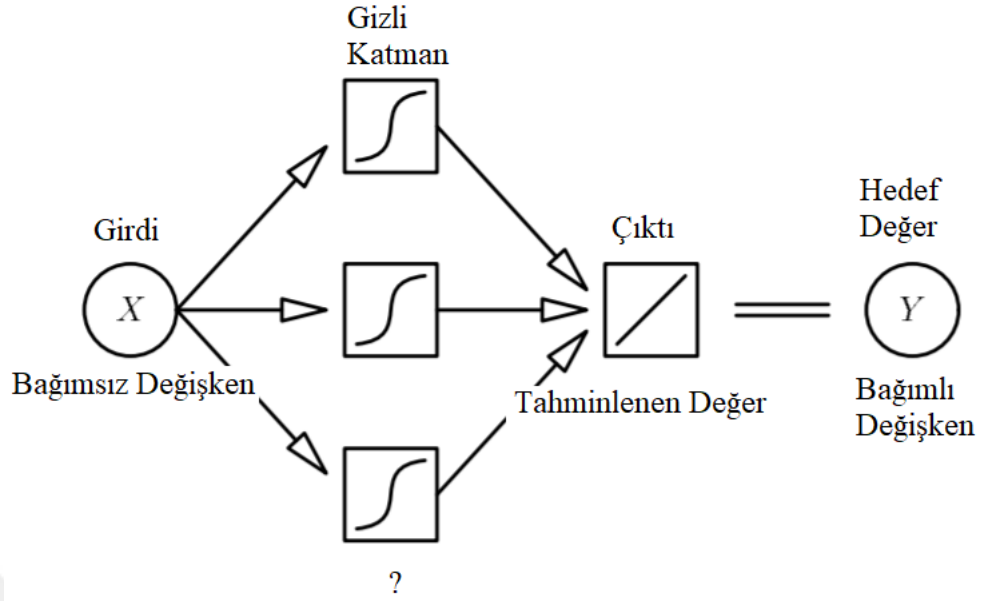
Katmanlı sinir ağlarında nöronlar katmanlı şekilde düzenlenir. Tek katmanlı ileri beslemeli ağlarda bir nöron çıkış katmanına ulaşır ve tersi yönde ilerlemez. Bir başka deyişle, bu ağ kesinlikle ileri beslemeli ve döngüsel olmayan bir ağdır. Tek katman adı, hesaplama düğümüne veya nöronuna atıfta bulunur. Kaynak düğümlerin girdi katmanı dahil edilmez çünkü bu düğümlerde hesaplama yapılmamaktadır (Haykin, 1994).

3.5. ÇOK KATMANLI SİNİR AĞI

Çok katmanlı sinir ağı, girdi ve çıktı katmanları arasında bir veya daha fazla katman (gizli veya ara katman da denir) bulunduran ağlardır. Tipik birçok katmanlı sinir ağı, iki birim arasında ağırlık katmanı bulundurur. Çok katmanlı sinir ağları tek katmanlı sinir ağlarına göre çok daha kompleks problemleri çözebilirler ancak eğitimleri daha zordur. Yine de bazı durumlarda eğitim daha başarılı olur çünkü doğru şekilde eğitilmemiş tek katmanlı ağ problemlerini çözme ihtimali vardır (Fausett Laurene, 1994).

İşlevsel bir bağlantı ağı fazladan gizli bir nöron katmanı sunar ancak bu aynı zamanda tahmin edilmesi gereken bir ağırlık katmanı daha ortaya çıkarır. Modeldeki gizli katman lojistik işlev gibi doğrusal olmayan bir fonksiyon kullanıyorsa; model parametreleri de doğrusal olmayan hale gelir. Ortaya çıkan model çok katmanlı algılayıcı olarak tanımlanır. Çok katmanlı sinir ağlarının regresyon ağındaki karşılıkları vardır. Şekil 13.'te çok katmanlı ağ ile basit doğrusal olmayan regresyon modelinin birlikte gösterimine yer verilmiştir. Basit doğrusal olmayan regresyon modelindeki bağımsız değişken, çok katmanlı ağ modelinde girdi değerinin yerini almıştır. Gizli katman ise basit doğrusal olmayan regresyon modelindeki doğrusal olmayan fonksiyon ve hata değerinin yerini almıştır (Sarle, 1994).

Şekil 13: Çok Katmanlı Ağ – Basit Doğrusal Olmayan Regresyon



Çok katmanlı sinir ağlarında sık kullanılan iki mimari olan ileri yayımlı ve geri yayımlı ağ mimarileri ele alınmıştır.

İleri yayılma/beslemeli sinir ağı, sinyal akışının bir döngü oluşmadan iletiildiği ve giriş katmanından gelen verilerin bir dizi gizli katman aracılığıyla çıktı katmanına iletiildiği bir yapay sinir ağı biçimidir (Shinde, 2020).

İleri beslemeli sinir ağları çoğunlukla Geri Yayılım Öğrenme Algoritması ile kullanılırlar.

Geri beslemeli sinir ağı ilk olarak 1970'lerde tanıtılmıştır. Geri beslemeli sinir ağı öğrenmeye yönelik eski yaklaşımlara göre çok daha hızlı çalıştığı ve daha öncesine çözülemeyen sorunları çözebildiği için bugün öğrenme algoritmaları içerisinde en önemli unsurlardan bir tanesidir (Nielsen, 2015).

Geriye beslemeli sinir ağı bir tür çok katmanlı ileri beslemeli ağıdır. Transfer işlevi sigmoid fonksiyonudur. Geri yayılım öğrenimi altında ağırlıkların ayarlanması nedeniyle ağı geri yayılım sinir ağı denir. Geri yayılım nöronu çıktısı aşağıdaki şekilde gösterilebilir:

$$a = f(Wp + b) \quad (3.7)$$

Burada f transfer fonksiyonu yani çıktı ile girdi arasındaki ilişkiyi gösterir fonksiyondur. Transfer fonksiyonu genellikle log-sigmoid, tan-sigmoid ya da doğrusal olabilir. Öğrenme süreci 2 bölümden oluşur. İlk bölümde ağ yapısı, önceki ağırlıklar


ve eşik değerleri ayarlanır, ikinci bölümde ise son katmanın eğimine göre ağırlıklar ve eşik değerleri yeniden düzenlenir. Geri yayılım algoritması bir tür δ -model algoritmalarından biridir ve bir tür denetimli öğrenmedir (Yang ve arkadaşları, 2013).

3.6. YİNELEMELİ/TEKRARLAYAN AĞLAR

Yinelenen sinir ağında (Recurrent Neural Network – RNN), birimler arasındaki bağlantılar yönlendirilmiş bir döngü oluştururlar (verileri ileriye doğru, aynı zamanda daha sonraki işlem aşamalarından önceki aşamalara kadar geriye doğru yayılırlar). Bu ağın dinamik zamansal davranış sergilemesine izin verir. İleri beslemeli sinir ağlarından farklı olarak yinelemeli ağlar kendi dahili belleğini rastgele girdi dizilerini işlemek için kullanabilir. Bu onları bölümlere ayrılmamış bağlantılı el yazısı tanıma, konuşma tanıma ve diğer genel sıra işlemcileri gibi görevlere uygulanabilir kılar (Fumo, 2017).

Tekrarlayan sinir ağları, en az bir geri bildirim döngüsüne sahip olmaları bakımından tek katmanlı ve çok katmanlılardan ayırt edilir. Tekrarlayan bir yapının varlığı, sinir ağının öğrenme ve temsil kapasitesi üzerinde derin bir etkiye sahiptir. Bu tür geri besleme döngülerinin kullanımı, ayrı durum için gecikme birimlerinin ($z - 1$ olarak gösterilir) ve sürekli durum için bütünleşmiş birimlerin kullanılmasını içerir. Yinelemeli ağlar, statik ağlarla çözülmesi mümkün olmayan bir çok uygulamanın kullanımına izin veren bir mimariye sahiptir (Rios ve arkadaşları, 2020).

Şekil 14: Yinelemeli Sinir Ağı Modeli



Yinelemeli ağların kısıtlamalarını aşmak için Schuster ve Kuldip 1997 yılında yayınladıkları makalede belirli bir zaman çerçevesinin geçmişinde ve geleceğinde mevcut tüm giriş bilgileri kullanılarak eğitilebilen çift yönlü tekrarlayan bir sinir ağı (Bidirectional Recurrent Neural Network – BRNN) önermişlerdir. Çift yönlü yinelemeli ağların yapısı basit bir yinelemeli ağın ileri zaman ve geri zaman olarak bölünmesiyle oluşturulmuştur. İleri zaman ve geri zamanlara ait çıkışlar birbirlerine bağlı değildir. Çift yönlü yinelemeli ağ, basit bir yinelemeli ağ gibi eğitilebilmektedir (Schuster ve Paliwal, 1997).


3.7. YAPAY SİNİR AĞI ALGORİTMALARI

Bir sinir ağının bir işlevi uygun şekilde ilişkilendirmesini, sınıflandırmasını veya yaklaştırmasını sağlamak ve ağın belirli bir girdi – çıktı vektörü ile hedef – çıktı vektörü arasındaki tahmin hatasını en aza indirmek için iç yapısını optimize etmemiz gerekir. Bir sinir ağının eğitim setinde bulunan tüm girdi ve çıktı vektörleri çiftlerinin genel tahmin hatalarını optimize etmek için tüm ağırlık ve eşiklerini yinelemeli olarak ayarlamaya çalışır. Tipik bir ağda milyonlarca ağırlık ve eşik değeri ve binlerce girdi-çıkış eğitim vektör çifti olabilir. Bir sinir ağı öğrenme kuralı bu nedenle basitçe tipik olarak yinelemeli bu değerleri otomatik olarak hesaplamak için bir prosedürdür. Genellikle elle hesaplanamayacak kadar çok şey olacaktır (Bishop, 2015).

3.7.1. Adaline ve Madaline

ADALINE ilk sinir ağı modelidir. İsmi Uyarlanabilen Doğrusal Nöron (ADaptive Linear Neuron)'dan gelmektedir. Widrow ve Hoff tarafından geliştirilmiştir (Widrow ve Hoff, 1960). Adaline modeli yapısı basitçe aşağıdaki şekilde gösterilebilir (Picton, 1994):

Şekil 15: ADALINE Yapısı



Adaline eğitilebilir bir sınıflayıcıdır. Girdiler X_k , $k=1, 2, \dots, n$, ağırlık vektörü $W_k=W_1, W_2, \dots, W_n$ ve bunların çıktıları $y_k=X_k \cdot W_k$ 'dir. Her girdi istenen yanıt sınıfına göre $a+1$ veya $a-1$ olarak sınıflandırılır. Adaline ağırlıkları değiştirerek ortalama karesel hatayı minimize etmeyi amaçlar. Hata hedeflenen çıktı (d_k) ile gerçekleşen çıktı (y_k) arasındaki farktı ve şu şekilde gösterilebilir: $e_k=d_k-y_k$ (Kozma ve arkadaşları, 2019).

Adaline gibi bir sinir ağı eğitim veya öğrenme aşamasındayken dikkate alınması gereken 3 faktör vardır. Bunlar; uygulanan girdiler, sistemin bu girdilere istenen tepkisinin olduğu bir eğitim setinden seçilir. Bir girdi modeli uygulandığında üretilen gerçek çıktı istenen çıktıyla karşılaştırılır ve hatayı hesaplamak için kullanılır. Ağırlıklar hatayı azaltmak üzere düzeltilir. Bu tür eğitime denetimli öğrenme denir çünkü bilinen çıktılarla ağı doğru çıktı üretmesi üzerine çalışılır. Alternatif olarak çıktıların önceden bilinmediği ve ağı uygun şekilde düzenlenmesine izin verildiği denetimsiz öğrenmedir (Picton, 1994).

MADALINE, Çoklu Uyarlanabilir Doğrusal Nöronlar (Many Adaptive Linear Neurons) olarak çok katmanlı ağlarda kullanılır. Her bir çıktı birimlerin girdi katmanlarına uygulanan eşik değerin bir sonucudur. Çıktılar girdi değerlerin doğrusal olmayan fonksiyonlarıdır. Gizli katmanların kullanılması, tek katmanlarda bulunmayan hesaplama yeteneği sağlar ancak eğitim sürecini de karmaşıktırır (Fausett Laurene, 1994).

3.7.2. Algılayıcı

1957’de Frank Rosenblatt’ın icat ettiđi algılayıcı (Perceptron) algoritması bir veya birden fazla girişe ve yalnızca bir çıkışa sahiptir. Bir sinir ađının en basit formu olarak kategorize edilen algılayıcı kavramı, ikili sınıflandırıcıların denetimli öğrenimini kolaylaştırmak için bir algoritma veya doğrusal sınıflandırıcı olarak kullanılır. Algılayıcı algoritması en basit haliyle, kullanımını verilerin ikili sınıflandırmasında bulur. Bu nedenle doğrusal bir sınıflayıcıdır. Algoritma algılayıcı adını, aynı adı taşıyan bir nöronun en temel biriminden alır (Goyal, 2020).

3.7.3. Geri Yayılım (Backpropagation)

Geri yayılım algoritması, muhtemelen bir sinir ađındaki en temel yapı taşıdır. İlk olarak 1960’larda tanıtılmış ve neredeyse 30 yıl sonra (1989) Rumelhart, Hinton ve Williams tarafından “Geri yayılan hatalarla temsilleri öğrenme” adlı bir makalede popüler hale getirilmiştir. Geri yayılım algoritması, bir sinir ađını zincir kuralı adı verilen bir yöntemle etkili bir şekilde eğitmek için kullanılır. Basit bir ifadeyle, bir ađdan her ileri geçişten sonra, geri yayılım modelin parametrelerini (ağırlıklar ve önyargılar) ayarlarken bir geriye doğru geçiş gerçekleştirir (Kostadinov, 2019).

Geri yayılım algoritması sonrası sinir ađlarında çok çeşitli uygulamalar ortaya çıkmaya başlamıştır. Tüm dünyada kabul gören bu algoritma sinir ađlarına dayalı yeni bilgi işleme teknolojilerinin yeteneklerini sunmasına imkan vermiştir. Geri yayılım algoritmasının çok katmanlı mimariye sahip sinir ađları modellerine Adaline öğrenme kuralının bir algılayıcıya genellemesi olarak düşünülebilir. Aynı zamanda genel olarak 1960’larda var olan parametreleştirilmiş ađlar için stokastik iniş yönteminin bir versiyonudur (Amari, 1993).

3.8. DERİN ÖĞRENME

Derin öğrenme, birden çok sinir ađı katmanını kullanarak, insan konuşmasını tanımadan hayvan görüntüleri sınıflandırmasına kadar deđişen kullanım örnekleriyle verileri ayıklamak ve dönüştürmek için kullanılan bir bilgisayar tekniğidir. Bu katmanların her biri, girdilerini önceki katmanlardan alır ve aşamalı olarak iyileştirir. Katmanlar, hatalarını en aza indiren ve doğruluklarını artıran algoritmalarla eğitilir. Bu şekilde ađ, belirli bir görevi gerçekleştirmeyi öğrenir (Howard ve Gugger, 2020).

3.8.1. Derin Öğrenmenin Tarihçesi

Gradyan iniş kullanan bir öğrenme yöntemi olan sinir ağları için geri yayılma (backpropagation) 1980'lerde yeniden keşfedilmiş ve bu alanda yenilenen ilerlemeye yol açmıştır. Çalışmalar hem insan sinir ağları (yani insan beyni) hem de etkili hesaplamalı sinir ağları için algoritmalar yaratmaya başlamıştır. Bu nihayetinde makine öğrenimi uygulamalarında derin öğrenme ağlarını ortaya çıkarmıştır. Yapay zeka araştırmacıları algoritmaları geliştirmek için sıkı matematiksel ve istatistiksel analizler uygulamaya başladıkça 1980'lerde ilerlemeler kaydedilmiştir. Gizli Markov Modelleri (Hidden Markov Models) konuşma tanıma uygulamalarında kullanılmaya başlanmıştır. Gizli Markov Modeli, gözlemlenmemiş (yani gizli) durumlara sahip bir modeldir. Büyük veri tabanları ile birleştiğinde çok daha sağlam konuşma tanıma ile sonuçlanmıştır. Makine çevirisi de geliştirilmiştir. Günümüzde bilinen makine öğreniminin ilk biçimi olan veri madenciliği geliştirilmiştir.

1990'ların başında, Vladimir Vapnik ve çalışma arkadaşları, Destek Vektör Makineleri (SVM) olarak bilinen hesaplama açısından güçlü bir denetimli öğrenim ağı sınıfı icat etmişlerdir. Bu ağlar örüntü tanıma, gerileme ve diğer makine öğrenimi problemlerini çözebilmektedir (Paluszek ve Thomas, 2020).

3.8.2. Derin Öğrenme Tipleri

Bu başlık altında derin öğrenme tiplerinden en yaygın kullanılan 3 tip derin öğrenme ele alınmıştır. Bunlar; Evrişimsel Sinir Ağları, Uzun-Kısa Dönem Hafızalı Ağlar ve Kapılı Tekrarlayan Hücre Ağı'dır.

3.8.2.1. Evrişimsel Sinir Ağları

Evrişimli sinir ağları (Convolutional Neural Networks) olarak bilinen evrişimsel ağlar ızgara benzeri topolojiye sahip verileri işlemek için özel bir tür sinir ağıdır. Evrişimsel ağlar pratik uygulamalarda muazzam derecede başarılı olmuştur. Adının içerisindeki evrişim, özel bir doğrusal işlem türüdür ve bu sinir ağının matematiksel bir işlem kullandığını gösterir. Evrişimli ağlar, katmanlarından en az birinde genel matris çarpımı yerine evrişimi kullanan basit ağlardır (Goodfellow ve arkadaşları, 2016).

Evrişimli sinir ağları, önceki başlıklarda açıklanan sinir ağlarına çok benzer yapıdadır. Öğrenilebilir ağırlıklar ve nöronlardan oluşurlar. Her nöron bazı girdiler

alır, bir iç çarpım gerçekleştirir ve isteğe bağlı olarak onu doğrusal olmayan bir şekilde devam ettirirler (Stanford University, 2020).

3.8.2.2. Uzun-Kısa Dönem Hafızalı Ağlar

Uzun-kısa dönem hafızalı ağlar (Long-Short Term Memory Networks - LSTM), önceki bölümde bahsedilen yinelemeli ağlardan daha iyi performans gösterdiği düşünülen bir yinelemeli ağ türüdür.

Yinelemeli ağla karşılaştırıldığında uzun-kısa dönem hafızalı ağlarda giriş akışı ve karışımını kontrol eden daha fazla kontrol mekanizması mevcuttur. Bu durum çıktıların daha esnek şekilde kontrol edilmesine imkan tanır. Bu nedenle uzun-kısa dönem hafızalı ağlarda daha fazla kontrol imkanı oluşur ve daha iyi sonuçlar elde edilir. Ancak bu durum çözümlerde karmaşıklık ve ekstra maliyetlere sebep olabilir (Rathor, 2018).

Uzun-kısa dönem hafızalı ağların bir çeşidi olarak Çift Yönlü Uzun-Kısa Dönem Hafızalı Ağlar kullanılmaktadır. Çift yönlü uzun-kısa dönem hafızalı ağlar, çift yönlü yinelemeli ağlar ve uzun-kısa dönem hafızalı ağların birleştirilmesiyle oluşturulmuştur. Çift yönlü uzun-kısa dönem hafızalı ağ yapısında ileri ağ, dizide her konumun sol tarafında birikir ve geri ağ dizide her konumun sağında birikir. Sırasıyla her iki ağın faaliyetleri depolanır ve dizi her iki yönde de işlendikten sonra çıktı etkinlikleri çıktı nöronlarının ağırlıklarını kullanarak nihai çıktılar hesaplanır. Eğitim esnasında elde edilen hatalar ağ kopyaları aracılığıyla geriye yayılım gösterir ve ağırlıklardaki değişiklikler uygulanır (Thireou ve Reczko, 2007).

3.8.2.3. Kapılı Tekrarlayan Hücre Ağı

Cho ve arkadaşları tarafından 2014 yılında her bir tekrarlayan birimin farklı zaman ölçeklerindeki bağımlılıkları uyarlamalı olarak yakalaması için kapılı tekrarlayan hücre (Gated Recurrent Unit – GRU) önerilmiştir. Uzun-kısa dönem hafızalı ağ birimine benzer şekilde kapılı tekrarlayan hücre ağı ayrı bir bellek hücreesine sahip olmadan birim içindeki bilgi akışını yumuşatan geçiş birimlerine sahiptir (Chung ve arkadaşları, 2014).

3.8.3. Optimizasyon Algoritmaları

Çoğu derin öğrenme algoritması, bir çeşit optimizasyon içerir. Optimizasyon, x 'i değiştirerek bazı $f(x)$ işlevlerini küçültme veya maksimize etme görevini ifade eder. Genellikle optimizasyon problemlerinin çoğu $f(x)$ 'i minimize etme açısından ifade

edilir. Maksimizasyon, $-f(x)$ 'in en aza indirilerek bir minimizasyon algoritması ile gerçekleştirilebilir. Küçültmek veya maksimize etmek istenilen işleve amaç işlevi veya ölçüt denir. Amaç işlevi minimize edildiğinde buna maliyet fonksiyonu, kayıp fonksiyonu veya hata fonksiyonu da denir (Goodfellow ve arkadaşları, 2016).

3.8.3.1. En Dik İniş Algoritması

Stokastik dik iniş algoritması (Stochastic Gradient Descent – SGD), birkaç örnek için girdi vektörünü göstermeyi, çıktıları ve hataları hesaplayıp bu örnekler için ortalama gradyanı bulup ve ağırlıkları buna göre ayarlamayı içerir. İşlem, eğitim setinden amaç fonksiyonunun ortalaması düşmeyi bırakana kadar birçok küçük örnek grubu için tekrarlanır. Bu algoritma stokastik olarak adlandırılır çünkü her küçük örnek grubu, tüm örnekler üzerinde ortalama gradyanın gürültülü bir tahminini verir. Bu basit prosedür, çok daha ayrıntılı optimizasyon teknikleriyle karşılaştırıldığında genellikle şaşırtıcı derecede hızlı bir şekilde iyi bir ağırlık seti bulur. Eğitimden sonra, sistemin performansı test seti adı verilen farklı bir dizi örnek üzerinde ölçülür. Bu, makinenin genelleme yeteneğini test etmeye hizmet eder. Test yeteneği eğitim sırasında hiç görmediği yeni girdiler üzerine mantıklı yanıtlar üretme başarısıdır (Lecun ve arkadaşları, 2015).

3.8.3.2. Adam Algoritması

Stokastik hedef fonksiyonlarının birinci dereceden gradyan tabanlı optimizasyonu için, düşük dereceli momentlerin uyarlanabilir tahminlerine dayanan bir algoritma olan Adam algoritmasının uygulanması basittir, hesaplama açısından etkilidir ve çok az bellek gereksinimi vardır. Gradyanların diyagonal olarak yeniden ölçeklendirilmesiyle değişmez ve veri ve/veya parametreler açısından büyük problemler için çok uygundur. Yöntem, aynı zamanda, sabit olmayan hedefler ve çok gürültülü ve/veya seyrek gradyanlı problemler için de uygundur. Hiper parametrelerin sezgisel yorumları vardır ve tipik olarak çok az ayarlama gerektirir. Adam algoritmasının ilham aldığı ilgili algoritmalarla bazı bağlantılar tartışılmıştır. Ayrıca, algoritmanın teorik yakınsama özellikleri analiz edilmiş ve çevrimiçi dışbükey optimizasyon çerçevesi altında bilinen en iyi sonuçlarla karşılaştırılabilir yakınsama oranına bir sınır sağlanmıştır. Ampirik sonuçlar, Adam algoritmasının pratikte iyi çalıştığını ve diğer stokastik optimizasyon yöntemlerine göre daha olumlu olduğunu göstermektedir (Kingma ve Lei Ba, 2017).

3.8.3.3. AdaGrad Algoritması

Stokastik dik iniş algoritmasında her ağırlık için aynı oran varken AdaGrad algoritmasında uyarlanabilir bir öğrenme oranı yani her parametre için bir ağırlık bulunmaktadır. AdaGrad algoritması sahip olunan önceki gradyanlara göre öğrenme oranını uyarlamalı olarak değiştirir. Önemlerine bağlı olarak daha büyük ya da daha küçük güncelleştirmeler yapabilmek için her parametreye güncelleme yapar. Bu algoritma özellikle boyutları nedeniyle her boyutu için manuel olarak farklı öğrenme oranının seçilmesinin pratikte mümkün olmadığı büyük ölçekli problemlerde kullanılmak üzere tasarlanmıştır. Eğitim sürecinin ne çok yavaş ne de çok değişken ve belirsiz olması için her boyuttaki öğrenme oranı parametresini uyarlamalı olarak ölçeklendirir (Singh, 2019).

3.8.3.4. Ortalama Karekök Yayılma Algoritması

Ortalama karekök yayılma (Root Mean Square Propagation – RMSprop) algoritması diğer algoritmalarından farklı bir şekilde öğrenme oranını ayarlama ihtiyacını ortadan kaldırmaktadır ve bunu otomatik olarak yapar. Ayrıca her parametre için farklı bir öğrenme hızı seçer (Kathuria, 2018).

OKY algoritması, sinir ağlarının eğitiminde kullanılan gradyan tabanlı bir optimizasyon tekniğidir. Geri yayılmanın mucidi Geoffrey Hinton tarafından önerilmiştir. Sinir ağları gibi çok karmaşık işlevlerin gradyanları, veriler işlev boyunca yayılırken yok olma ya da patlama eğilimindedir. OKY, mini-toplu öğrenme için stokastik bir teknik olarak geliştirmiştir. OKY, gradyanı normalleştirmek için kare gradyanların hareketli ortalamasını kullanarak bu sorunu ele alır. Bu normalleştirme adım boyutunu (momentum) dengeler, patlamayı önlemek amacıyla büyük gradyanlar için adımı azaltır ve kaybolmayı önlemek amacıyla küçük gradyanlar için adımı artırır (DeepAI, 2020).

3.8.4. Öğrenme Oranı

Öğrenme oranı spesifik olarak 0,0 ile 1,0 arasında küçük bir pozitif değere sahip, sinir ağlarının eğitiminde kullanılan yapılandırılabilir bir hiperparametredir. Öğrenme oranı genellikle küçük Yunan harfi eta (η) ile gösterilir. Eğitim sırasında hatanın geri yayılması ağıdaki bir düğümün ağırlıklarının sorumlu olduğu hata miktarını tahmin eder. Ağırlık tam miktarla güncellenmektense öğrenme oranına göre oranlanır. Geleneksel olarak 0,1 değerine sahip öğrenme oranının 0,1 * (tahmini ağırlık

hatası) veya ağırlıklar her güncellendiğinde tahmini ağırlık hatasının %10'unun güncellendiği anlamına gelir (Brownlee, 2019b).

3.8.5. MATLAB Derin Öğrenme Aracı

Rasmus Berg Palm'ın Derin Öğrenme Araç Kutusu, derin öğrenme için bir MATLAB araç kutusudur. Derin İnanç Ağları (Deep Belief Nets), Yığılanmış Otomatik Kodlayıcılar (Stacked Autoencoders), Evrişimli Sinir Ağları (Convolutional Neural Nets) ve diğer sinir ağı işlevlerini içerir. MathWorks File Exchange aracılığıyla kullanılabilir (Paluszek ve Thomas, 2020).

Uygulama bölümünde kullanılmış katmanların ayrıntılı tanımları aşağıda incelenmiştir (MATLAB Toolbox Help):

sequenceInputLayer: Sıralı bir girdi katmanı, sıralı verileri bir ağa girer.

lstmLayer: Bir LSTM (Uzun-Kısa Dönem Hafıza Modeli) katmanı, zaman serilerindeki zaman adımları ve sıra verileri arasındaki uzun vadeli bağımlılıkları öğrenir. Katman, eğitim sırasında uzun dizilerde gradyan akışını iyileştirmeye yardımcı olabilecek ek etkileşimler gerçekleştirir.

fullyconnectedLayer: Tamamen bağlı katman girişi bir ağırlık matrisi ile çarpılır ve ardından bir sapma vektörü ekler.

regressionLayer: Bir regresyon katmanı, regresyon problemleri için yarı ortalama kare hata kaybını hesaplar.

biLstmLayer: Çift yönlü bir LSTM (BiLSTM) katmanı, zaman serilerinin zaman adımları veya sıra verileri arasındaki iki yönlü uzun vadeli bağımlılıkları öğrenir. Bu bağımlılıklar, ağın her adımında tüm zaman serilerinden öğrenmesi istendiğinde faydalı olabilir.

reluLayer: ReLU katmanı, girişin her bir ögesi için bir eşik işlemi gerçekleştirir; burada sıfırdan küçük herhangi bir değer sıfıra ayarlanır.

Aşağıda bulunan Şekil 16.'da şimdiye kadar bahsedilen kodların Çift Yönlü Uzun-Kısa Dönem Hafızalı model örneği MATLAB R2019b paket programı üzerinde gösterilmiştir.

Şekil 16: MATLAB Katmanlar

```
switch layerSet
case 'lstm'
    layers = [sequenceInputLayer(numFeatures)
              lstmLayer(numHiddenUnits)
              fullyConnectedLayer(numResponses)
              regressionLayer];
case 'bilstm'
    layers = [sequenceInputLayer(numFeatures)
              bilstmLayer(numHiddenUnits)
              fullyConnectedLayer(numResponses)
              regressionLayer];
case 'two lstm'
    layers = [sequenceInputLayer(numFeatures)
              lstmLayer(numHiddenUnits)
              reluLayer
              lstmLayer(numHiddenUnits)
              fullyConnectedLayer(numResponses)
              regressionLayer];
otherwise
    error('Only 3 sets of layers are available');
end
```

Kaynak: Yazar tarafından derlenmiştir.

analyzeNetwork: analyzeNetwork(layers), katmanlar tarafından belirtilen derin öğrenme ağ mimarisini analiz eder. analyzeNetwork işlevi, ağ mimarisinin etkileşimli bir görselleştirmesini görüntüler, ağdaki hataları ve sorunları algılar ve ağ katmanları hakkında ayrıntılı bilgi sağlar. Katman bilgisi katman etkinleştirmelerinin boyutlarını ve öğrenilebilir parametreleri, öğrenilebilir toplam parametre sayısını ve tekrarlayan katmanların durum parametrelerinin boyutlarını içerir. Ağ mimarisini görselleştirmek ve anlamak için ağ analizcisini kullanılır. Mimari doğru tanımlandığında eğitimden önce sorunları tespit edilir. Ağ algılamalarını analiz eden sorunlar arasında eksik veya bağlantısız katmanlar, yanlış boyutlandırılmış katman girişleri, yanlış sayıda katman girişi ve geçersiz Tablo yapıları bulunur.

Uygulama bölümünde bahsedilecek olan öğrenme ayarları (training options) için tanımlamalara bu bölümde yer verilmiştir (MATLAB Toolbox Help):

trainingOptions('adam'): Adam (Adaptive Moment Estimation – Uyarlanabilir Moment Tahmini) optimize edici için öğrenme oranı bilgileri, L2 düzenlilik faktörü ve mini parti boyutu dahil eğitim seçeneklerini içerir.

MaxEpoch: Eğitim için kullanılacak maksimum dönem sayısı, pozitif tam sayı olarak belirtilir. Yineleme, bir mini parti kullanarak kayıp fonksiyonunu en aza indirmeye yönelik gradyan iniş algoritmasında atılan bir adımdır. Bir dönem, eğitim algoritmasının tüm eğitim seti boyunca tam geçiştir.

InitialLearnRate: Pozitif skaler olarak belirtilen, eğitim için kullanılan ilk öğrenme oranıdır. Öğrenme oranı çok düşükse, eğitim uzun zaman alır. Öğrenme oranı çok yüksekse, eğitim yetersiz bir sonuca ulaşabilir.

LearnRateSchedule: Mimari olarak belirtilen öğrenme hızı çizelgesi ayarlarıdır. Öğrenme oranını ayarlamak için yöntem türünü belirten metot alanına sahiptir. Olası yöntemler şunlardır:

'none': Öğrenme oranı eğitim boyunca sabittir.

'piecewise': Öğrenme oranı eğitim sırasında periyodik olarak düşer.

Eğer yöntem 'piecewise' ise iki alan daha içerir:

DropRateFactor: Eğitim sırasında öğrenme oranının düştüğü çarpımsal faktördür.

DropPeriod: Eğitim sırasında öğrenme oranına yapılan ayarlamalar arasında geçen dönemlerin sayısıdır.

Shuffle: Aşağıdakilerden biri olarak belirtilen veri karıştırma seçeneğidir:

'once': Eğitim ve doğrulama verileri eğitimden önce bir kez karıştırılır.

'never': Veriler asla karıştırılmaz.

'every-epoch': Her eğitim döneminden önce eğitim verilerini karıştırılır ve her ağ doğrulamasından önce veriler karıştırılır. Mini parti boyutu eğitim verilerinin sayısını eşit olarak bölmezse, trainNetwork her bir dönemin son tam mini partisine uymayan eğitim verilerini atar. Her dönemde aynı verilerin atılmasını önlemek için Shuffle değerini "every epoch" olarak ayarlanmalıdır.

Verbose: 1 (doğru) veya 0 (yanlış) olarak belirtilen komut penceresinde eğitim ilerleme bilgilerini görüntüleme göstergesidir. Görüntülenen bilgiler, dönem numarası, yineleme numarası, geçen süre, mini parti kaybı, mini parti doğruluğu ve temel öğrenme oranını içerir. Bir regresyon ağı eğitildiğinde doğruluk yerine kök ortalama kare hatası (RMSE) gösterilir. Ağ eğitim sırasında doğrulanırsa görüntülenen bilgiler ayrıca doğrulama kaybını ve doğrulama kesinliğini (veya RMSE) içerir.

Şekil 17.'de ağın analiz kodlarının örnek kullanımı yer almaktadır.

Şekil 17: MATLAB Ağ Analizi

```
analyzeNetwork(layers);  
options = trainingOptions('adam', ...  
    'MaxEpochs',300, ...  
    'GradientThreshold',1, ...  
    'InitialLearnRate',0.005, ...  
    'LearnRateSchedule','piecewise', ...  
    'LearnRateDropPeriod',125, ...  
    'LearnRateDropFactor',0.2, ...  
    'Shuffle','every-epoch', ...  
    'Verbose',0, ...  
    'Plots','training-progress');
```

Kaynak: Yazar tarafından derlenmiştir.



DÖRDÜNCÜ BÖLÜM

UYGULAMA

4.1. UYGULAMANIN AMACI

Uygulamanın amacı tüm dünyada merakla takip edilen Bitcoin'in diğer finansal değerlerle ilişkisini Engle-Granger Eşbütünleşme Testi ile araştırıp (Tekinay ve Deveci Kocakoç, 2018), Bitcoin ile ilişkili bulunan finansal değerleri kullanarak derin öğrenme metoduyla Bitcoin davranışlarını öğrenip tahmin yapacak sinir ağı modeli oluşturmaktır. Bu çalışmada Kripto para piyasasındaki altcoin ve dünya piyasalarındaki diğer finansal değerlerle Bitcoin ilişkisi incelenmiş, Bitcoin ile uzun dönemde dengeye geldiği anlaşılan değişkenlerle derin öğrenme yöntemi kullanılarak Bitcoin'in davranışı modellenmiş ve elde edilen modellerle 31 günlük, 45 günlük ve 60 günlük tahminlemeler yapılmıştır. Oluşturulan modellerin hata oranları bölüm sonunda değerlendirilmiştir.

4.2. VERİLER VE ANALİZ YÖNTEMLERİ

Bitcoin ile ilişkisinin incelenmesi için Bitcoin Cash, Dash, Decred, Ethereum, Litecoin, Teter, Nem, Vechain, Ripple ve Monero, dünyaca ünlü borsalardan Dow Jones, Nasdaq, StandartvePoor, Russel 2000, Shanghai Stock Exchange ve Nikkei 225 çalışmada yer almıştır. Avustralya doları, Brezilya reali, İsviçre frangı, Kanada doları, Çin yuani, euro, sterlin, Japon yeni ve emtialar arasından ise altın vadeli işlemleri ve petrol fiyatları çalışmaya dahil edilmiştir. Tüm finansal kaynaklar ve Bitcoin verileri Amerikan doları cinsinden ele alınmıştır. Çalışmada 2017-2020 yılları arasındaki günlük fiyatlar dikkate alınmıştır. Bitcoin'in 7/24 online sistem üzerinde çalışıyor olması nedeniyle örneklem hacmi haftaiçi belirli saatlerde işlem yapmaya izin veren platformlara göre uyarlanmıştır.

4.2.1. Temel İstatistikler

İncelenen değişkenlerin 2017 – 2020 yılları kapsamında temel istatistikleri Tablo 3.'de belirtilmiştir. Ele alınan değişkenlerin veri sayıları 733 ile 1075 arasında değişmektedir. Standart sapmalar içerisinde en yüksek sapmaya sahip değişkenin Bitcoin olması dikkat çekmektedir. Ayrıca değişkenlerin genel olarak sağa çarpık oldukları gözlemlenmektedir.

Tablo 1: Temel İstatistikler

	Gözlem Sayısı	Minimum Değer	Maksimum Değer	Ortalama	Standart Sapma	Çarpıklık
Bitcoin (BTC)	1075	3.236,76	19.345,49	7.900,42	2.706,82	0,63
Bitcoin Cash (BCH)	1075	77,37	3.909,00	554,07	538,80	2,38
Dash	1075	39,87	941,10	193,34	178,21	1,91
Decred (DCR)	1075	9,29	122,74	35,88	25,86	1,40
Ethereum (ETH)	1075	84,28	1.397,48	316,71	232,17	1,88
Litecoin (LTC)	1075	23,46	359,13	81,66	54,19	2,04
Nem (XEM)	1075	0,03	1,81	0,16	0,24	3,55
Ripple (XRP)	1075	0,14	2,78	0,41	0,33	3,56
Tether (USDT)	1075	0,97	1,12	1,00	0,01	4,25
VeChain (VET)	1075	0,00	0,08	0,01	0,01	1,98
Dow Jones Industrial Average (DJI)	742	19.028,36	29.440,47	25.525,54	1.683,87	-0,22
Nasdaq Composit (IXIC)	740	6.257,86	11.258,44	7.944,74	1.015,73	1,12
SveP 500 (GSPC)	741	2.290,71	6.439,46	2.859,53	257,03	3,89
Russel 2000 (RUT)	741	988,71	6.439,46	1.538,14	218,53	14,95
SSE Composite Index (000001.SS) *	739	1.425,35	3.563,64	2.932,70	376,41	-1,86
Nikkei 225 (N225) **	733	16.570,57	24.376,17	21.910,39	1.243,50	-0,81
Avustralya Doları	767	0,57	0,81	0,72	0,04	-0,07
Brezilya Reali	767	0,17	0,32	0,26	0,04	-0,36
İsviçre Frangı	893	0,98	1,11	1,02	0,02	1,27
Kanada Doları	893	0,69	0,82	0,76	0,02	-0,18
Çin Yuanı	778	6,27	7,18	6,80	0,25	-0,62
Euro	767	1,07	1,25	1,15	0,04	0,65
Sterlin	767	1,15	1,43	1,30	0,05	0,31
Japon Yeni	767	0,01	0,01	0,01	0,00	0,05
Altın Vadeli İşlemleri (ZGG1)	777	1.204,90	2.069,40	1.463,61	168,28	1,25

4.2.2. Engle – Granger Eşbütünleşme Testi

Çalışmada ele alınan tüm değişkenlerin durağanlık seviyeleri ADF Birim Kök Testi ile analiz edilmiştir. Eşbütünleşme testi kısıtlarından bir tanesi, teste dahil edilen tüm değişkenlerin aynı seviyede durağan olması olduğu önceki bölümde açıklanmıştır. Buradan yola çıkarak uygulanan analiz sonucunda altcoinlerden Teter, Ripple ve para birimlerinden İsviçre Frangı düzey değerlerinde durağan bulunduğu için eşbütünleşme analizine dahil edilmemiştir. Altın fiyatları düzey değeri ve sabitli durumda 0,05 önem seviyesinde durağan bulunmuş, trend ve sabitliken 0,1 seviyesinde durağan bulunmamış ve sabit ve trend olmadığında durağan bulunmadığı için analize dahil edilememiştir. ADF Birim Kök Testi sonuçlarına göre diğer tüm finansal araçların 1. derecede durağan oldukları görülmüş ve eşbütünleşme analizi gerçekleştirilmiştir.

Tablo 4.'te eşbütünleşme olduğu belirlenen değişkenlerin durağanlık sonuçları verilmiştir. Tüm değişkenler Bitcoin ile analize dahil edilmiştir. Bu nedenle Bitcoin için gecikme değeri girilmemiştir. Bitcoin'in de seviye düzeyinde durağan olmayıp, birinci farkında durağan olması analize uygun bir çalışma alanı yaratmıştır.

Eşbütünleşme ilişkisinin olduğu altcoinler ve Bitcoin arasında Granger nedensellik testi uygulanmış ve Bitcoin ve Decred, Dash, Ethereum, Nem ve VeChain altcoinleri arasında çift yönlü nedensellik ilişkisi olduğu ortaya konmuştur.

Tablo 2: Birim Kök Testi ve Eşbütünleşme Testi Sonuçları

		Standart Birim Kök Testi ve Engle-Granger Testi Sonuçları							
		Seviye				Birinci Fark			
	Gecikme Değerleri	Sabit	Trend ve Sabit	Trendsiz ve Sabitsiz	Sonuç	Sabit	Trend ve Sabit	Trendsiz ve Sabitsiz	Sonuç
Decred	10	0.4908	0.2509	0.2741	Durağan değil	0.0000	0.0000	0.0000	Durağan
Residual		0.0000	0.0000	0.0000	Eşbütünleşme var				
Dash	8	0.8868	0.8680	0.5212	Durağan değil	0.0000	0.0000	0.0000	Durağan
Residual		0.0000	0.0000	0.0000	Eşbütünleşme var				
Nem	13	0.2349	0.2645	0.0648	Durağan değil	0.0000	0.0000	0.0000	Durağan
Residual		0.0000	0.0000	0.0000	Eşbütünleşme var				
Bitcoincash	10	0.2912	0.1908	0.1426	Durağan değil	0.0000	0.0000	0.0000	Durağan
Residual		0.0000	0.0000	0.0000	Eşbütünleşme var				
Ethereum	14	0.4428	0.6085	0.3376	Durağan değil	0.0000	0.0000	0.0000	Durağan
Residual		0.0000	0.0000	0.0000	Eşbütünleşme var				
VeChain	7	0.1839	0.2746	0.1210	Durağan değil	0.0000	0.0000	0.0000	Durağan
Residual		0.0000	0.0000	0.0000	Eşbütünleşme var				
Bitcoin*		0.1171	0.3312	0.6183	Durağan değil	0.0000	0.0000	0.0000	Durağan

4.2.3. Granger Nedensellik Testi

Çalışmaya dahil edilen ve eşbütünleşme bulunan tüm değişkenlerle Bitcoin arasındaki ilişkinin yönünün belirlenmesi amacıyla Granger Nedensellik Testi uygulanmıştır. Bu test için E-view 11 paket programı kullanılmıştır.


Tablo 3: Granger Nedensellik Testi Sonuçları

Dependent variable: CLOSE_DECREDED			
Excluded	Chi-sq	df	Prob.
CLOSE_BTC	2.962.853	10	0.0010
All	2.962.853	10	0.0010
Dependent variable: CLOSE_BTC			
Excluded	Chi-sq	df	Prob.
CLOSE_DECREDED	2.221.749	10	0.0140
All	2.221.749	10	0.0140
Dependent variable: CLOSE_BTC			
Excluded	Chi-sq	df	Prob.
CLOSE_BCH	4.044.076	10	0.0000
All	4.044.076	10	0.0000
Dependent variable: CLOSE_BCH			
Excluded	Chi-sq	df	Prob.
CLOSE_BTC	2.813.323	10	0.0000
All	2.813.323	10	0.0000
Dependent variable: CLOSE_DASH			
Excluded	Chi-sq	df	Prob.
CLOSE_BTC	3.444.611	8	0.0000
All	3.444.611	8	0.0000
Dependent variable: CLOSE_BTC			
Excluded	Chi-sq	df	Prob.

CLOSE_DASH	4.712.503	8	0.0000
All	4.712.503	8	0.0000
Dependent variable: CLOSE_BTC			
Excluded	Chi-sq	df	Prob.
CLOSE_ETH	9.058.497	14	0.0000
All	9.058.497	14	0.0000
Dependent variable: CLOSE_ETH			
Excluded	Chi-sq	df	Prob.
CLOSE_BTC	6.000.788	14	0.0000
All	6.000.788	14	0.0000
Dependent variable: CLOSE_XEM			
Excluded	Chi-sq	df	Prob.
CLOSE_BTC	1.046.786	13	0.0000
All	1.046.786	13	0.0000
Dependent variable: CLOSE_BTC			
Excluded	Chi-sq	df	Prob.
CLOSE_XEM	1.649.598	13	0.0000
All	1.649.598	13	0.0000
Dependent variable: VET_CLOSE			
Excluded	Chi-sq	df	Prob.
CLOSE_BTC	1.720.950	7	0.0161
All	1.720.950	7	0.0161
Dependent variable: CLOSE_BTC			
Excluded	Chi-sq	df	Prob.
VET_CLOSE	3.155.642	7	0.0000
All	3.155.642	7	0.0000

Granger nedensellik testi sonuçları 2 aşamalı olarak gösterilmektedir. 1. bölümde bağımsız değişken karşısında bağımlı değişkenin nedensellik hipotezi kurulur. 2. bölümde ise bağımlı değişken karşısında bağımsız değişkenin nedensellik hipotezi kurulur. H_0 hipotezi nedensellik ilişkisi yoktur, H_1 hipotezi nedensellik ilişkisi vardır. Tablo genelindeki tüm sonuçlarda Prob değeri 0,05'ten küçük olduğu için H_0 hipotezi reddedilmektedir. Bu durumda ele alınan altcoinler ve Bitcoin'in birbirleri arasında nedensellik ilişkisi olduğu sonucuna varılmaktadır.

Şekil 18: Granger Nedensellik Testi Şeması



4.2.4. Yapay Sinir Ağı ve Derin Öğrenme


Çalışmadaki hedef derin öğrenme yöntemiyle Bitcoin davranışlarını öğrenip Bitcoin fiyatlarını tahminleyecek bir yapay sinir ağı modeli oluşturmaktır. Bunun için MATLAB R2019b paket programının Deep Learning Toolbox aracı kullanılmıştır. 1075 adet verinin %70'i eğitim seti, %30'u test seti için ayrılmıştır. X bağımsız değişken olarak eşbütünleşme gösterdiği bulunan değişkenler (altcoinler) ve Y bağımlı değişken olarak Bitcoin ele alınmıştır.

4.3. MODELLER

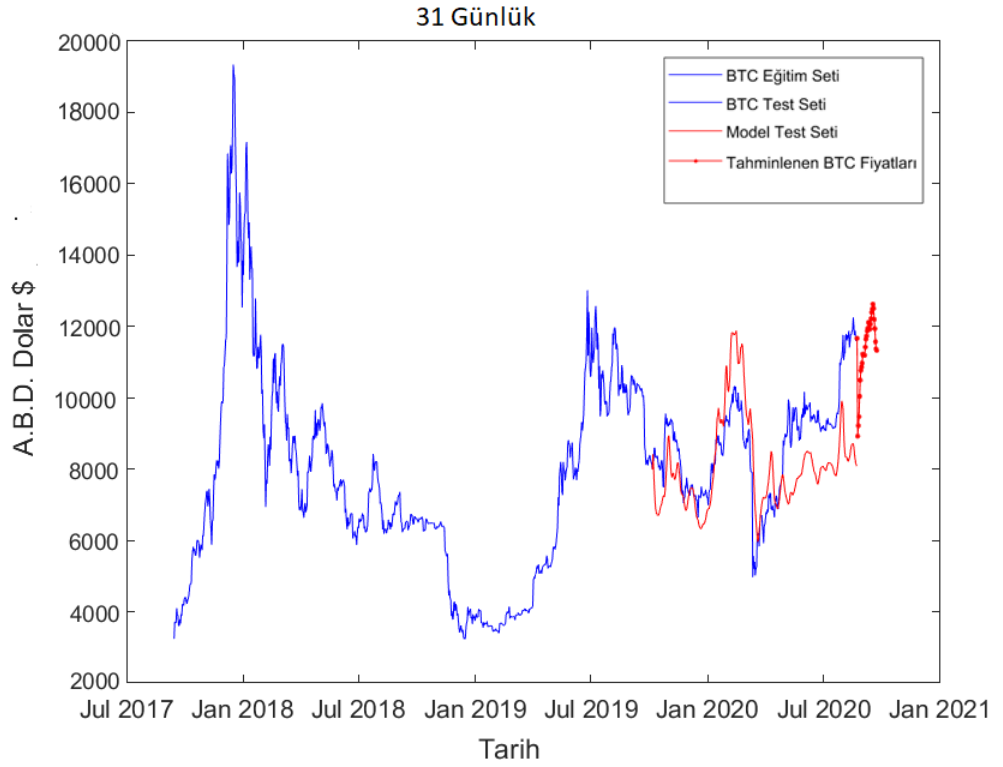
Uygulamada 6 adet model oluşturulmuştur. Tüm değişkenler için aynı yapıdaki sinir ağı modeli kullanılmıştır. Modeller on defa çalıştırılmış ve her bir deneme sonucu, ortalama hata kareleri kökü, 31-45-60 günlük tahmin değerleri kaydedilmiştir. Tüm modellerdeki deneme sonuçlarının ortalamaları alınmış ve elde edilen değerler nihai değer olarak incelenmiştir.

Tablo 6'da eğitim seti ile eğitilmiş verilerin gerçekleşen model üzerindeki grafiği çizdirilmiştir.

Şekil 19: Bitcoincash ve Bitcoin Modeli 1. Deneme Sonucu




Şekil 20: Bitcoincash ve Bitcoin Modeli Grafiği – 31 Günlük



Şekil 19.'da BCH-BTC modelinin yapay sinir ağı çalıştırıldıktan sonra eğitim seti karşısında gösterdiği performans ve hatalar yer almaktadır.


Şekil 20.'de BCH-BTC modelinin 1. Denemesi sonucu eğitim seti, test seti ve 31 günlük tahmin değerleri yer almaktadır. Mavi gerçekleşen BTC değerleri, kırmızı düz çizgi eğitim sonrası çalışmış modelin BTC değeri ve kırmızı nokta ise modelin test amacıyla oluşturduğu BTC değerlerini vermektedir.

Şekil 21: Bitcoincash ve Bitcoin Modeli Grafiği – 45 Günlük



Şekil 21.'de BCH-BTC modeli 1. deneme eğitim seti, test seti ve 45 günlük tahmin seti grafiği yer almaktadır.

Şekil 22: Bitcoincash ve Bitcoin Modeli Grafiği – 60 Günlük




Şekil 22.'de BCH-BTC modelinin 60 günlük tahmin sonucunu içeren grafiği bulunmaktadır.

Bitcoincash ve diğer tüm eşbütünleşik bulunmuş değerler için modeller 10 kez çalıştırılmıştır. Nihai sonuç olarak tüm sonuçların ortalaması alınmış ve tahminlenen değerler ile gerçekleşen değerler çeşitli istatistiklerle yorumlanmıştır.

Şekil 23.'de BCH-BTC modelinin 31 günlük tahmin ve gerçekleşme grafiğine yakından bakılmaktadır.

31-45 ve 60 günlük için tahmin değerlerine Ortalama Mutlak Yüzde Hatası (Mean Absolute Percentage Error – MAPE) Ortalama Hata Kareleri Kökü (Root Mean Square Error - RMSE) istatistikleri hesaplanmış ve Tablo 11., Tablo 12. ve Tablo 13.'te ayrı ayrı paylaşılmış ve yorumlanmıştır.

Şekil 23: Bitcoincash ve Bitcoin Modeli Tahmin Grafiği



Tablo 4: 31 Günlük Tahmin İstatistikleri

Ortalama Mutlak Hata Yüzdesi - MAPE					
BCH Tahmin	DASH Tahmin	DCR Tahmin	ETH Tahmin	VET Tahmin	XEM Tahmin
12,98%	14,52%	6,94%	7,83%	9,50%	8,63%
Ortalama Hata Kareleri Kökü - RMSE					
BCH Tahmin	DASH Tahmin	DCR Tahmin	ETH Tahmin	VET Tahmin	XEM Tahmin
1520,64	1664,78	933,27	972,92	1070,04	1196,05

Ortalama mutlak hata yüzdesinin sıfıra yakın olması istenir. Bu şekilde incelendiğinde 31 günlük tahmin içerisinde ortalama mutlak yüzde hatasına göre en iyi modeli Decred yapmıştır.

Ortalama hata kareleri kökü istatistiğine göre istatistiğin 0 çıkması modelin mükemmel yani hatasız olduğunu göstermektedir. En küçük ortalama hata kare kökü Decred’te elde edilmiştir.

Tablo 5: 45 Günlük Tahmin İstatistikleri

MAPE					
BCH Tahmin	DASH Tahmin	DCR Tahmin	ETH Tahmin	VET Tahmin	XEM Tahmin
8,11%	9,47%	6,89%	3,37%	9,18%	3,47%
RMSE					
BCH Tahmin	DASH Tahmin	DCR Tahmin	ETH Tahmin	VET Tahmin	XEM Tahmin
1173,10	1244,75	903,32	502,30	1055,84	658,95

45 günlük tahminlere göre en iyi modeli her iki istatistiğe göre de Ethereum modeli vermiştir.

Tablo 6: 60 Günlük Tahmin İstatistikleri

Ortalama Mutlak Hata Yüzdesi - MAPE					
BCH Tahmin	DASH Tahmin	DCR Tahmin	ETH Tahmin	VET Tahmin	XEM Tahmin
3,17%	5,75%	9,38%	3,64%	10,59%	3,92%
Kök Ortalama Kare Hatası - RMSE					
BCH Tahmin	DASH Tahmin	DCR Tahmin	ETH Tahmin	VET Tahmin	XEM Tahmin
574,21	941,27	1375,01	737,35	1417,65	695,95

60 günlük tahmin sonuçlarına göre en düşük hatalı model Bitcoincash'te bulunmuştur.

Tüm istatistiklerin aynı sonucu vermesi sonuca olan güveni arttırmıştır. Buna göre 31 günlük tahminlemede Decred, 45 günlük tahminlemede Ethereum ve 60 günlük tahminlemede Bitcoincash en düşük hatalı modeller sunmaktadır.


4.4. ANALİZ SONUÇLARI VE YORUMLAR

Uygulamada öncelikli olarak Bitcoin ile altcoinler, döviz kurları, borsa ve emtialar arasındaki eşbütünleşme ilişkisi incelenmiştir. Bu analiz sonrası Bitcoin ile 6 adet altcoinin uzun dönemde dengeye geldiği anlaşılmış ve bu değişkenlerle Bitcoin arasında çift yönlü nedensellik bulunmuştur. Ardından son yıllarda başarısıyla ünlülenen derin öğrenme yöntemi yapay sinir ağı modeline uygulanmıştır. Her bir altcoin ve Bitcoin ilişkisi için toplamda 6 adet model kurulmuştur. Kurulan bu modeller için 14.09.2017 – 23.08.2020 tarihleri arasındaki veriler kullanılmıştır. 1075 adet verinin %70'i eğitim seti, %30'u test seti için kullanılmıştır. Her model 10'ar kez çalıştırılmış ve sonuçları kaydedilmiştir. Modellerle 31,45 ve 60 günlük tahmin setleri oluşturulmuştur. Her model için elde edilen 10 deneme sonucu kaydedilmiş ve gerçekleşen değerlerle modellere ait tahmin sonuçlarının ortalamaları MAPE ve RMSE istatistikleriyle karşılaştırılmıştır. Sonuçlara göre 31 günlük tahmin için Decred, 45 günlük tahmin için Ethereum, 60 günlük tahmin için ise Bitcoincash modeli en düşük hatayı vermektedir. Sonuçlar grafiksel olarak Tablo 11., Tablo 12. ve Tablo 13.'te gösterilmiştir. Her iki istatistiğin sonucunun eşit olması güvenilirliği arttırmıştır.

Ele alınan verilere yapısal değişiklik testi, CUSUM test (Cumulative Sum of the Recursive Residuals) ile Eviews 11 paket programı kullanılarak uygulanmıştır.

Her veri setinde belirli dönemlerde yapısal değişiklik olduğu saptandıktan sonra yapısal değişikliğin olmadığı dönemler için yeniden veri seti oluşturulmuştur. Bu serilerin model performansının önceki modellerle karşılaştırılabilmesi için önceki analize uygun şekilde gerçekleştirilmiştir. Dash ve Vechain altcoinlerinin yapısal değişikliğe uğradığı belirlenen dönemler dikkate alındığında modellenen uygun veri kalmadığı için karşılaştırmaya dahil edilememiştir.

Şekil 24: BCHBTC Modeli için CUSUM Test




Şekil 24.'te Bitcoincash ve Bitcoin regresyon modeli için 2018 1. çeyreğinden 2018 3. çeyreğinin sonuna kadar ve 2019 1. çeyrekten itibaren yapısal kırılma olduğu görülmektedir.

Şekil 25: DCRBTC Modeli için CUSUM Test




Şekil 25.'te Decred ve Bitcoin regresyon modelinin 2018 3. çeyrekten 2019 1. Çeyreğine kadar ve 2019'un 3. çeyreğinden itibaren yapısal kırılma olduğu görülmektedir.

Şekil 26: XEMBTC Modeli için CUSUM Test



Şekil 26.'da Nem ve Bitcoin regresyon modelinin 2017 4. Çeyreğinde kısa dönemli, 2018 ortasından itibaren tamamen yapısal kırılma olduğu görülmektedir.

Şekil 27: ETHBTC Modeli için CUSUM Test



Şekil 27.'de Ethereum ve Bitcoin modeli için 2018 1. Çeyreğinden 2018 4. Çeyreğinin başına kadar ve 2019 ortasından itibaren yapısal değişiklik olduğu görülmektedir.


CUSUM Test sonuçları incelendiğinde her modelin ardışık hataların kümülatif toplamının artarak büyüdüğü gözlemlenmektedir. Böyle durumlarda belirsizlik olduğu düşünülebilmektedir.

Tablo 7: Model Performans Karşılaştırması

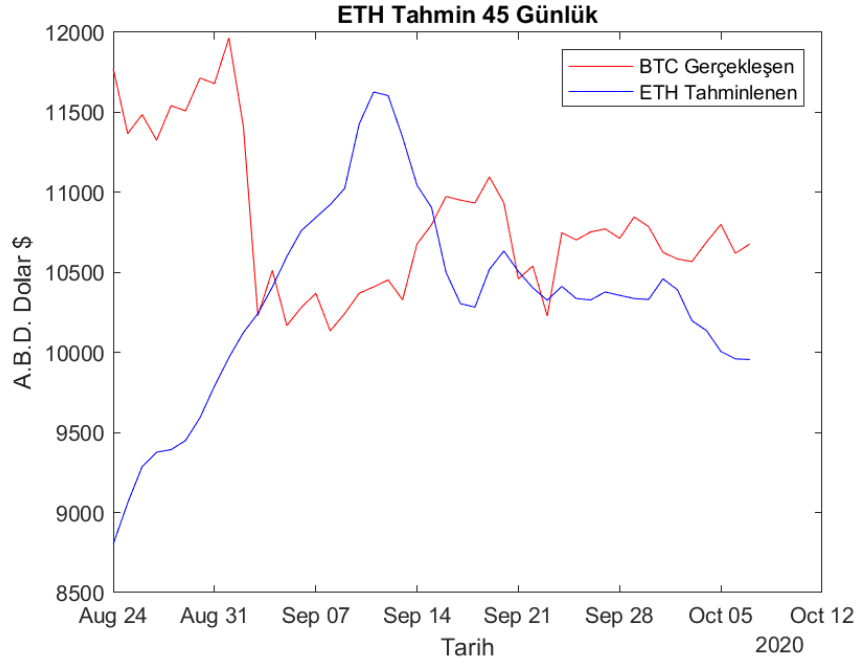
	MAPE					
	BCH Tahmin	DASH Tahmin	DCR Tahmin	ETH Tahmin	VET Tahmin	XEM Tahmin
Tüm Dönemler	12,98%	14,52%	6,94%	7,83%	9,50%	8,63%
Yapısal Kırılma Hariç	9,74%		17,68%	46,54%		37,30%
	MAE					
	BCH Tahmin	DASH Tahmin	DCR Tahmin	ETH Tahmin	VET Tahmin	XEM Tahmin
Tüm Dönemler	1.429,48	1.516,49	684,34	770,16	944,29	970,46
Yapısal Kırılma Hariç	594,31		848,12	2.632,34		5.535,79
	RMSE					
	BCH Tahmin	DASH Tahmin	DCR Tahmin	ETH Tahmin	VET Tahmin	XEM Tahmin
Tüm Dönemler	1520,64	1664,78	933,27	972,92	1070,04	1196,05
Yapısal Kırılma Hariç	944,87		857,40	2.725,42		6.280,05

Yapısal kırılma dönemleri dikkate alınarak düzenlenen veri setleriyle oluşturulan model performansları incelendiğinde, her üç istatistikte de Bitcoincash altcoinini ile oluşturulan modelin performansının arttığı gözlemlenmektedir. Dahil edilen diğer altcoinler için performanslarda iyileşme gözlenmemiştir. Her iki dönemin de dahil edilmesiyle 31 günlük en iyi modelin Nem, 45 ve 60 günlük modeller içerisinde en yüksek performansın Bitcoincash ile gerçekleştirildiği belirlenmiştir.


Yapısal kırılmanın dikkate alınmadığı modellerden elde edilen tahmin sonuçları ve gerçekleşme değerleri sırasıyla Decred, Ethereum ve Bitcoincash için Şekil 24., Şekil 25. ve Şekil 26.'da görselleştirilmiştir.

Şekil 28: DCR - BTC Gerçekleşme ve Tahmin Karşılaştırması

Şekil 29: ETH - BTC Gerçekleşme ve Tahmin Karşılaştırması



Şekil 30: BCH - BTC Gerçekleşme ve Tahmin Karşılaştırması



Şekil 28.'de 31 günlük tahmin görseli bulunmaktadır. Tahmin ile gerçekleşen fiyat değerleri incelendiğinde, tahmin fiyatları tahmin dönemi sonunda başlangıç

fiyatından yüksek deęerde dönemi kapatacađını öngörmüşken gerçekleşen durumda başlangıç fiyatı, bitiş fiyatının yukarısında bulunmaktadır.

Şekil 29.'da da 45 günlük tahmin ve gerçekleşme fiyatları bulunmaktadır. Başlangıç tahmin fiyatının bitiş tarihindeki tahmin fiyatının aşağısında olması beklenmiş ancak gerçekleşen fiyatlarda başlangıç fiyatı bitiş fiyatının aşağısında seyretmiştir.

Şekil 30.'da diđer 2 tahminin aksine tahminlenen fiyatlar ve gerçekleşen fiyatlar birlikte hareket etmiştir. Modelin tahminine göre fiyatların yükseleceđi beklentisi gerçekleşen fiyatlarla birlikte desteklenmiştir.



SONUÇ

Bu çalışmanın hazırlanmasındaki en büyük motivasyon, günümüzdeki en popüler ve her sektörün bir gün kullanımına uygun hale getirilebilen bir teknolojiye sahip, mevcut ekonomik sisteme alternatif oluşturabileceği tartışılan kripto para piyasasının farklı değişkenlerle açıklanmak istenmesidir.

Bitcoin ile hayatımıza sadece kripto para değil aynı zamanda altyapısını oluşturan, güvenilir bir sisteme sahip Blockchain teknolojisi de girmiş oldu. ... Blockchain teknolojisinin ne kadar güçlü olduğu Bitcoin'in yaratımından bugüne kadar hiçbir saniye sistemin duraklamamış olmasıyla anlaşılabilir. Günümüzde oldukça yüksek meblağlarda teknolojik yatırımların yapıldığı bankalarda, hükümetlerde ve çok uluslu şirketlerde dahi yıllar içerisinde sistemsel hatalar ve kapanmalar görülmektedir. Ancak 2009 yılından beri Bitcoin'in dahil edildiği sistemde hiçbir aksama yaşanmamıştır.

Bu çalışmayla Bitcoin'in ele alınan emtialar, dünyaca ünlü endeksler ve para birimleriyle değil, sadece altcoinlerle eşbütünleşme göstermesi, kripto para piyasaları için beklendik bir sonuçtur. Özellikle model tahminleri içerisindeki maksimum performans gösteren altcoinler Decred, Ethereum ve Bitcoincash için elde edilen sonuçlar tatmin edicidir. 2021 yılı itibariyle Decred altcoininin piyasa değeri 740 milyon dolar, Ethereum piyasa değeri 150 milyar dolar ve Bitcoincash piyasa değeri 8 milyar dolardır.

Yapılan bu tez çalışmasında Bitcoin'in uzun dönemde birlikte hareket ediyor olabileceği düşünülen dünyaca ünlü çeşitli endeksler, emtialar, para birimleri ve altcoinler ele alınmıştır. Bitcoin'in ilişkili olabileceği düşünülen değişkenlerle ilişki boyutu eşbütünleşme testleriyle dikkate alınmıştır. Eşbütünleşme olduğu saptanan değişkenlerle nedensellik analizi yapılarak ilişkinin yönü saptanmıştır. Ardından bu yöne uygun olarak derin öğrenme yöntemi kullanılmış ve model oluşturulmuştur. Bu modelle Bitcoin fiyatları tahminlenmiştir. Modellerin performansı, tahminlenen fiyatlarla gerçekleşen fiyatların karşılaştırıldığı 3 çeşit istatistikle incelenmiştir. Ardından zaman serilerinde yapısal değişiklik olabileceği düşünülerek serilere yapısal değişiklik testi uygulanmıştır. Yapısal değişiklik olduğu görülen serilerin verileri bu dönemlere göre yeniden düzenlenerek modelin içerisine yeniden dahil edilmiştir.

Yapısal deęişiklięin saptandıęı ve yapısal deęişiklięin dikkate alınmadıęı model sonuçları tez sonunda karşılaştırılmıştır. Bu anlamda kripto para piyasasında yatırımcı veya muhtemel yatırımcıların ortak düşüncesi; Bitcoin'in tahminlenebilir veya spekülatif bir piyasa oluşu görüşlerine ışık tutmak amacıyla ekonometrik analizler gerçekleştirilmiş ve bu sonuçlara göre kişilerin piyasayı daha etkin şekilde yorumlayabilmelerine imkan tanınmış ve literatüre dahil edilerek erişilebilir bir pozisyona gelmesi sağlanmıştır.



KAYNAKÇA

Abiodun, O. I., Jantan, A., Omolara, A. E., Dada, K. V., Mohamed, N. A. E., ve Arshad, H. (2018). *State-of-the-art in artificial neural network applications: A survey*. Elsevier Limited. (23.08.2020).

Alonso-Monsalve, S., Suárez-Cetrulo, A. L., Cervantes, A., ve Quintana, D. (2020). *Convolution on neural networks for high-frequency trend prediction of cryptocurrency exchange rates using technical indicators*. Journal of Expert Systems with Applications, (149).

Amari, S. ichi. (1993). *Backpropagation and stochastic gradient descent method*. Neurocomputing, 5(185–196).

Atik, M., Köse, Y., Yılmaz, B., ve Sağlam, F. (2015). *Kripto Para: Bitcoin ve Döviz Üzerine Etkileri*. Bartın Üniversitesi İ.İ.B.F. Dergisi 14(247-261).

Awoke, T., Minakhi, R., Mohanty, L., ve Satapathy, S. C. (2020). *Bitcoin Price Prediction and Analysis Using Deep Learning Models*. Springer: India 134(630–640).

Back, A. (2002). *Hashcash -A Denial of Service Counter-Measure*. <http://www.hashcash.org/papers/hashcash.pdf>. (15.07.2019).

Bishop, J. M. (2015). *History and philosophy of neural networks*. <https://www.researchgate.net/publication/271841595>. (19.01.2021).

Blau, B. M. (2018). *Price dynamics and speculative trading in Bitcoin*. Research in International Business and Finance. 43(15-21).

Brownlee, J. (2019a). *A Gentle Introduction to the Rectified Linear Unit (ReLU)*. <https://machinelearningmastery.com/rectified-linear-activation-function-for-deep-learning-neural-networks/>. (15.12.2020).

Brownlee, J. (2019b). *How to Configure the Learning Rate When Training Deep Learning Neural Networks*. <https://machinelearningmastery.com/learning-rate-for-deep-learning-neural-networks/>. (15.12.2020).

Buscema, P. M., Massini, G., Breda, M., Lodwick, W. A., ve Newman, F. (2018). *Artificial Adaptive Systems Using Auto Contractive Maps*. Poland: Springer.

Cambridge Dictionary. *Digital Money*. <https://dictionary.cambridge.org/tr/sözlük/ingilizce/digital-currency>. (30.11.2020).

Cavalli, S., ve Amoretti, M. (2020). *CNN-Based Multivariate Data Analysis for Bitcoin Trend Prediction*. *Applied Soft Computing Journal*. 149.

Chaum, D. (1982). *Blind Signatures For Untraceable Payments*. Springer-Verlag (199–203).

Chen, W., Xu, H., Jia, L., ve Gao, Y. (2021). *Machine learning model for Bitcoin exchange rate prediction using economic and technology determinants*. *International Journal of Forecasting*, 37(1): 28–43.

Chen, Z., Li, C., ve Sun, W. (2020). *Bitcoin price prediction using machine learning: An approach to sample dimension engineering*. *Journal of Computational and Applied Mathematics*, 365.

Chung, J., Gulcehre, C., ve Cho, K. (2014). *Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling*. (Yayınlanmamış Makale).

Ciaian, P., Rajcaniova, M., ve Kancs, A. (2018). *Virtual relationships: Short-and long-run evidence from BitCoin and altcoin markets*. Journal of International Financial Markets, Institutions and Money. 52(173-195).

Corsello, P. (2018). *What is Cryptocurrency?. Numbers, numbers and more numbers*. <https://medium.com/datadriveninvestor/what-is-cryptocurrency-20fb4009e718>. (3.01.2020).

Costa, P. N. Da. (2018). *Nobel economist Stiglitz sees no legal functions for bitcoin: "We have a good medium of exchange called the dollar."*. <https://www.businessinsider.com/stiglitz-calls-for-regulating-bitcoin-which-he-says-would-kill-demand-2018-1>. (15.12.2020).

Çelebi, Ö. C. (2020). *Neural Networks and Pattern Recognition Tutorial*. https://www.byclb.com/TR/Tutorials/neural_networks/. (15.06.2020).

Çevik, Y. E., Tanrıöve, C., ve Koçoğlu, Ş. (2016). *Bitcoin Piyasalarının Etkinliği, Likiditesi ve Oynaklığı (Efficiency, Liquidity and Volatility of Bitcoin Markets)*. Journal of Business Research - Turk, 8(2).

DeepAI (2020), *RMSProp Definition*. <https://deepai.org/machine-learning-glossary-and-terms/rmsprop>. (30.12.2020).

Draper, N. R., ve Smith, H. (1998). *Applied Regression Analysis*. Toronto: Wiley – Interscience Publication.

Dwyer, G. P. (2015). *The economics of Bitcoin and similar private digital currencies*. Journal of Financial Stability, 17(81-91).

Eberly College of Science (2021). *Coefficient of Determination*. <https://online.stat.psu.edu/stat500/lesson/9/9.3>. (15.01.2021).

Erdem, K. (2020). *Time Series Analysis (Zaman Serileri Analizi)*.
<https://medium.com/@kardelennerdem/time-series-analysis-zaman-serileri-analizi-68edf3014359>. (13.12.2020).

Ethereum (2021). *What is Ethereum?* <https://ethereum.org/en/what-is-ethereum/>.
(09.09.2020).

European Central Bank. (2019). *Electronic money*.
https://www.ecb.europa.eu/stats/money_credit_banking/electronic_money/html/index.en.html. (31.10.2020).

European Space Agency (2021). *Neural Network Glossary*.
<https://envisat.esa.int/handbooks/meris/CNTR4-2-5.html>. (19.12.2020).

Frankenfield, J. (2018). *Bitcoin Cash*.
<https://www.investopedia.com/terms/b/bitcoin-cash.asp>. (13.09.2020).

Frankenfield, J. (2019a). *Tether (USDT)*.
<https://www.investopedia.com/terms/t/tether-usdt.asp>. (21.09.2020).

Frankenfield, J. (2019b). *VeChain*.
<https://www.investopedia.com/terms/v/vechain.asp>. (21.09.2020).

Freund's, J. E. (2004). *Mathematical Statistics with Applications*. Pearson Prentice Hall.

Fumo, D. (2017). *A Gentle Introduction To Neural Networks Series*
<https://towardsdatascience.com/a-gentle-introduction-to-neural-networks-series-part-1-2b90b87795bc>. (19.12.2020).

García, S., Fernández, A., Luengo, J., ve Herrera, F. (2009). *A study of statistical techniques and performance measures for genetics-based machine learning: Accuracy and interpretability*. *Soft Computing*, 13(10):(959–977).

Garner, B. (2019). *What Is Decred (DCR)? A Guide on Decentralized Blockchain Governance*. <https://coincentral.com/decred-lowdown-decentralized-blockchain-governance/>. (12.12.2020).

Goodfellow, I., Bengio, Y., ve Courville, A. (2016). *Deep Learning*. Massachusetts Institute of Technology.

Goyal, K. (2020). *Perceptron Learning Algorithm: How it works?* <https://www.upgrad.com/blog/perceptron-learning-algorithm-how-it-works/>. (13.09.2020).

Grant, M. (2020). *Digital Money Definition*. <https://www.investopedia.com/terms/d/digital-money.asp>. (18.02.2020).

Gulve, A. (2020). *Everything about Components of Time Series: Part-1*. <https://medium.com/@aishwaryagulve97/everything-about-components-of-time-series-part-1-7476fb521477>. (11.09.2020).

Haykin, S. (1994). *Neural Networks*. A Comprehensive Foundation. Ontario: Pearson.

Hileman, G., ve Rauchs, M. (2017). *Global Cryptocurrency Benchmarking Study*. <https://www.crowdfundinsider.com/wp-content/uploads/2017/04/Global-Cryptocurrency-Benchmarking-Study.pdf>. (18.03.2020).

Hjalmarsson, E., ve Österholm, P. (2010). *Testing for cointegration using the Johansen methodology when variables are near-integrated: Size distortions and partial remedies*. *Empirical Economics*, 39(1):(51–76).

Howard, J., ve Gugger S. (2020). *Deep Learning for Coders with fastai and PyTorch*, Canada: O'Reilly Media.

Hyndman, R. J., ve Athanasopoulos, G. (2018). *Forecasting: Principles and Practice*. Monash University.

Ingham, G. (2004). *The Nature of Money*. Cambridge: Polity Press.

Iordanova, T. (2020). *Introduction to Stationary and Non-Stationary Processes*. <https://www.investopedia.com/articles/trading/07/stationary.asp>. (15.11.2020).

Ji, S., Kim, J., ve Im, H. (2019). *A Comparative Study of Bitcoin Price Prediction Using Deep Learning*. *Mathematics*. 7(898).

Jiang, X. (2020). *Bitcoin Price Prediction Based on Deep Learning Methods*. *Journal of Mathematical Finance*, 10(01):(132–139).

Kathuria, A. (2018). *Intro to optimization in deep learning: Momentum, RMSProp and Adam*. <https://blog.paperspace.com/intro-to-optimization-momentum-rmsprop-adam/>. (05.01.2021).

Khandelwal, R., (2021). *A Simple Guide to Understanding Blockchain*, <https://medium.com/swlh/a-simple-guide-to-understanding-blockchain-8dd09356b153>. (15.03.2021).

Kingma, D. P., ve Lei Ba, J. (2015). *ADAM: A Method For Stochastic Optimization*. ICLR 2015.

Kostadinov, S. (2019). *Understanding Backpropagation Algorithm*. <https://towardsdatascience.com/understanding-backpropagation-algorithm-7bb3aa2f95fd>.(18.12.2020).

Kozma, R., Rlipi, C., Choe, Y., ve Morabito, F. C. (2019). *Artificial Intelligence In The Age Of Neural Networks And Brain Computing*. London: Academic Press.

Kumar, R., ve O'Brien, S. (2019). 2019 *Findings from the Diary of Consumer Payment Choice*. <https://www.frbsf.org/cash/publications/fed-notes/2019/june/2019-findings-from-the-diary-of-consumer-payment-choice/>. (17.11.2020).

Lahmiri, S., ve Bekiros, S. (2019). *Cryptocurrency forecasting with deep learning chaotic neural networks*. *Chaos, Solitons and Fractals*, 118:(35–40).

Lahmiri, S., ve Bekiros, S. (2020). *Intelligent forecasting with machine learning trading systems in chaotic intraday Bitcoin market*. *Chaos, Solitons and Fractals*, (133).

Laurene, F. (1994). *Fundamentals of Neural Network, Architectures, Algorithm And Applications*. Prentice Hall.

Law, L., Sabett, S. ve Solinas, J. (1997). *How to Make a Mint: The Cryptography of Anonymous Electronic Cash*. *American University Law Review*, 46(4):(1131-1162).

Lecun, Y., Bengio, Y., ve Hinton, G. (2015). *Deep learning*.

Liu, M., Li, G., Li, J., Zhu, X., ve Yao, Y. (2020). *Forecasting the price of Bitcoin using deep learning*. *Finance Research Letters*, August.

Luz, N. (2019). *Digital is the Cash*. Anesis Global Concepts Limited.

Maind, S. B., ve Wankar, P. (2014). *Research Paper on Basic of Artificial Neural Network*. International Journal on Recent and Innovation Trends in Computing and Communication, 2(1):(96–100).

Maitra, S. (2019). *Time Series Forecasting using Granger's Causality and Vector Auto-regressive Model*. <https://towardsdatascience.com/granger-causality-and-vector-auto-regressive-model-for-time-series-forecasting-3226a64889a6>. (18.12.2020).

Majumder, M. (2015). *Impact of in Face of Climatic Water Shortage Urbanization on Aberrations*. Wiadomosci parazytologiczne. 16(1).

Mcfarlane, G. (2019). *What Is Litecoin, and How Does It Work?* <https://www.investopedia.com/articles/investing/040515/what-litecoin-and-how-does-it-work.asp>. (02.07.2020).

Mcleay, M., Radia, A., ve Thomas, R. (2014). *Money in the modern economy: an introduction*. www.youtube.com/watch?v=ziTE32hiWdk. (17.11.2020).

Mohamed, I. E. (2008). *Time Series Analysis Using SAS - Part I - The Augmented Dickey Fuller (ADF) Test*. NESUG 2008

Montgomery, D. C., Peck, E. A., ve Vining, G. G. (2012). *Introduction to Linear Regression Analysis*. New Jersey: Wiley Publication.

Nakamoto, S. (2008). *Bitcoin: A Peer-to-Peer Electronic Cash System*. www.bitcoin.org. (10.10.2019).

Nakano, M., Takahashi, A., ve Takahashi, S. (2018). *Bitcoin technical trading with artificial neural network*. Physica A: Statistical Mechanics and Its Applications, 510:(587–609).

Nielsen, M. A. (2015). *Neural Networks and Deep Learning*. Determination Press. <http://neuralnetworksanddeeplearning.com>. (01.10.2020).

OECD. (2005). *Irregular component of a time series Definition*. <https://stats.oecd.org/glossary/detail.asp?ID=6697>. (23.11.2020).

Okwu, M. O., ve Tartibu, L. K. (2021). *Metaheuristic Optimization: Nature-Inspired Algorithms Swarm and Computational Intelligence, Theory and Applications Cham*. Springer International Publishing.

Paluszek, M., ve Thomas, S. (2020). *Practical MATLAB Deep Learning: A Project-Based Approach*.

Picton, P. (1994). *Introduction to Neural Networks*. London: Macmillan Press.

Prins, J. (2012). *Engineering Statistics Handbook*. <https://www.itl.nist.gov/div898/handbook/pmc/section4/pmc442.htm>. (26.10.2020).

Quiniou, M., (2019). *Blockchain: The Advent of Disintermediation*. London: Wiley.

Rathor, S. (2018). *Simple RNN vs GRU vs LSTM :- Difference lies in More Flexible control*. <https://medium.com/@saurabh.rathor092/simple-rnn-vs-gru-vs-lstm-difference-lies-in-more-flexible-control-5f33e07b1e57>. (11.10.2020).

Reiff, N. (2020). *Bitcoin vs. Ethereum: What's the Difference?* <https://www.investopedia.com/articles/investing/031416/bitcoin-vs-ethereum-driven-different-purposes.asp#citation-1>. (13.12.2020).

Rios, J. D., Alanis, A. Y., Daniel, N. A., ve Franco, C. L. (2020). *Neural Networks Modeling and Control. In Neural Networks Modeling and Control*. London: Academic Press.

Sarle, W. S. (1994). *Artificial Neural Networks and Statistical Model*. Proceedings of the Nineteenth Annual SAS Users Group International Conference. (9).

Schuster, M., ve Paliwal, K. K. (1997). *Bidirectional Recurrent Neural Networks*. IEEE Transactions On Signal Processing, 45(11).

Seth, S. (2019). *All About NEM (XEM), the Harvested Cryptocurrency*. <https://www.investopedia.com/tech/meet-nem-xem-harvested-cryptocurrency/>. (15.03.2020).

Shafie-khah, M., (2020). *Blockchain-based Smart Grids*. London: Academic Press.

Sharma, Sagar. (2017). *Activation Functions in Neural Networks*. <https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>. (11.12.2020).

Sharma, S., ve Athaiya, A. (2020). *Activation Functions In Neural Networks*. International Journal of Engineering Applied Sciences and Technology (4).

Shinde, S. (2020). *Understanding Artificial Neural Networks—Perceptron to Multi-layered Feedforward Neural Network*. Towards AI — The Best of Tech, Science, and Engineering. <https://towardsai.net/p/deep-learning/understanding-artificial-neural-networks-perceptron-to-multi-layered-feedforward-neural-network-c6864b4a11b7>. (10.12.2020).

Sia Partners. (2015). *Virtual money: the next step after PSD2 and Instant Payments*. <https://www.sia-partners.com/en/news-and-publications/from-our-experts/what-virtual-money>. (11.12.2019).

Silva de Souza, M. J., Almudhaf, F. W., Henrique, B. M., Silveira Negredo, A. B., Franco Ramos, D. G., Sobreiro, V. A., ve Kimura, H. (2019). *Can artificial*

intelligence enhance the Bitcoin bonanza. The Journal of Finance and Data Science, 5(2):(83–98).

Silva, I. N. Da, Spatti, D. H., Flauzino, R. A., Liboni, L. H. B., ve Alves, S. F. dos R. (2017). *Artificial Neural Networks A Practical Course*. Springer.

Singh, A. (2019). *Optimization Algorithms in Deep Learning*. <https://medium.com/@ashwin8april/optimization-algorithms-in-deep-learning-4f2c3b53f9f>. (11.12.2020).

Stanford University. (2020). *Convolutional Neural Networks for Visual Recognition*. <https://cs231n.github.io/neural-networks-1/>. (23.12.2020).

Strickland, J. (2015). *Components of Time Series Data*. <https://www.linkedin.com/pulse/component-time-series-data-jeffrey-strickland-ph-d-cmsp>. (11.12.2020).

Suhas, D. (2017). *Using the Right Mean for Meaningful Performance Analysis, Data Analysis*. <https://blog.catchpoint.com/2017/05/18/using-mean-performance-analysis/>. (13.11.2020).

Tarı, R. (2014). *Ekonometri*. Kocaeli: Umuttepe Yayınları.

Tarver, E. (2020). *Monetary Aggregates Definition*. <https://www.investopedia.com/terms/m/monetary-aggregates.asp>. (13.11.2019).

Tekinay, M., ve Deveci Kocakoç, İ. (2018). *A Study of Relations Between Bitcoin, Currencies, Stock Exchanges and Commodities*. Detay Yayıncılık.

The Economist, (1988) *Get Ready For The Phoenix*. <https://www.goldbroker.com/news/the-economist-get-ready-for-a-world-currency-by-2018-1179>, 306:(9–10).

Thireou, T., ve Reczko, M. (2007). *Bidirectional long short-term memory networks for predicting the subcellular localization of eukaryotic proteins*. IEEE/ACM Transactions on Computational Biology and Bioinformatics, 4(3):(441–446).

Tiwari, A., Jana, R. K., Das, D., ve Roubaud, D. (2018). *Informational efficiency of Bitcoin: An extension*. Economics Letters, 163:(106–109).

Topalođlu, E. E. (2019). *Kripto Para Bitcoin ve Döviz Kurları İlişkisi: Yapısal Kırılmalı Eşbütünleşme ve Nedensellik Analizi*. Celal Bayar Üniversitesi Sosyal Bilimler Dergisi, 17(2).

Urquhart, A. (2016). *The inefficiency of Bitcoin*. Economics Letters, 148:(80–82).

Wang, P. (2009). *Financial Econometrics*. London: Routledge.

Weatherford, J. (1997). *The History of Money*. Three Rivers Press.

Widrow, B., ve Hoff, M. E. (1960). *Adaptive Switching Circuits*. Stanford University.

Yacobi, Y. (1995). *Efficient electronic money*. Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), 917(19):(151–163).

Yalta, A. T. (2011). *Zaman Serileri Ekonometrisine Giriş*. [http://yalta.etu.edu.tr/files/ekonometri2-09-zaman-serileri-ekonometrisine-giris-\(s2,0\).pdf](http://yalta.etu.edu.tr/files/ekonometri2-09-zaman-serileri-ekonometrisine-giris-(s2,0).pdf). (13.11.2020).

Yang, S., Ting, T. O., Man, K. L., ve Guan, S. U. (2013). *Investigation of neural networks for function approximation*. Procedia Computer Science, 17:(586–594).

Yeager, K. (2020). *Pearson Correlation*. Kent State University Library. <https://libguides.library.kent.edu/SPSS/PearsonCorr>. (10.10.2020).

Yegnanarayana, B. (1994). *Artificial neural networks for pattern recognition*. *Sadhana*. 19(189-238).

Zahar, T. (2020). *How Does Dash Cryptocurrency Work?* <https://cryptoticker.io/en/dash-cryptocurrency-work/>. (08.05.2020).

Zaions, C. (2021). *Granger Causality Real Statistics Using Excel* <https://www.real-statistics.com/time-series-analysis/time-series-miscellaneous/granger-causality/>. (12.01.2021).

Zamboglou, D. (2018). *A comprehensive ripple analysis*. <https://medium.com/datadriveninvestor/ripple-explained-4df46678e0bd>. (14.03.2020).

Zhang, Z. (2016). *A gentle introduction to artificial neural networks*. *Annals of Translational Medicine*, 4(19).

Zivot, E., ve Jiahui, W. (2006). *Vector Autoregressive Models for Multivariate Time Series*. In *Modeling Financial Time Series with S-PLUS* New York: Springer.



EKLER

EK. 1

Küresel Para Birimine Hazır Olun

Otuz yıl sonra, Amerikalılar, Japonlar, Avrupalılar ve diğer birçok zengin ülkedeki insanlar ve nispeten fakir olanlar muhtemelen alışverişleri için aynı para birimiyle ödeme yapacaklar. Fiyatlar dolar, yen veya D-mark (Deutsche Mark) olarak değil, diyelim ki anka kuşundan alınacak. Anka kuşu, şirketler ve alışveriş severler tarafından tercih edilecektir, çünkü o zamana kadar geçen yirminci yüzyılda, ekonomik yaşamda çok fazla bozulmanın nedeni gibi görünecek olan bugünün ulusal para birimlerinden daha uygun olacaktır.

1988'in başında bu garip bir tahmin gibi görünüyor. Nihai para birliği önerileri beş on yıl önce çoğaldı, ancak 1987'deki aksilikleri pek öngörmediler. Büyük ekonomi hükümetleri, radikal para reformu için döviz kurlarının yönetim sistemini bir iki adım daha öteye taşımaya çalıştı, ki bu görünüşe göre mantıklı bir başlangıç. Temel ekonomi politikalarında iş birliği yapılmamasından ötürü, bunu korkunç bir şekilde bastırdılar ve Ekim ayı borsa çöküşüne (19 Ekim 1987 Kara Pazartesi) neden olan faiz oranlarındaki artışı provoke ettiler. Bu olaylar döviz kuru reformcularını hızlandırdı. Piyasa çöküşü, onlara politik iş birliğinin bahanesinin hiçlikten daha kötü olabileceğini ve gerçek iş birliğinin mümkün olana kadar (yani hükümetler bir miktar ekonomik egemenliği teslim edene kadar) sabit düzeyli para birimlerini kurmaya çalışacağını öğretti.

Ancak hükümetlerin makroekonomik politika ile ilgili uluslararası anlaşmalar imzalamalarına ve (hala zor gözükse de) bunlara bağlı kalmalarına rağmen, döviz kurlarının kendilerine bırakılamayacağı inancı artıyor. Louvre Anlaşması'nın ve Eylül 1985'teki Plaza Anlaşması'nın, para birimi istikrarsızlığı kriziyle başa çıkmak için acil önlemler olduğunu unutmayın. 1983 ve 1985 yılları arasında dolar, Amerika'nın ticaret ortaklarının para birimlerine karşı %34 oranında arttı; 1985 yılından beri %42 düştü. Bu değişiklikler uluslararası karşılaştırmalı getiri düzenini 4 yılda tüm sistemin altındaki ekonomik güçlerin yapabileceğinden daha sert şekilde çarpıttı.

Geçtiğimiz birkaç gün içinde, başka bir dolar çöküşünden korkan dünyanın ana merkez bankaları yeniden para piyasalarına birlikte müdahale ettiler (bkz. Sayfa 62).

İngiltere'den Bay Nigel Lawson gibi pazar seven bakanlar, döviz kuru istikrarının nedeni olarak gösterildi. Japon yetkililer, ana sanayi ekonomileri için EMS (Emerging Markets veya European Monetary System) benzeri planlar fikrini ciddiye alıyor. Louvre'un utanç verici başarısızlığından bağımsız olarak, döviz kurları hakkında bir şeyler yapılması gerektiğine dair inanç devam ediyor.

1988 yılında bir şeyler olacak. Ve bir sonraki para birimi anlaşması imzalanınca, sonuncusu ile aynı şekilde sonuçlanacak. Çökecek. Hükümetler, ulusal hedeflerini uluslararası istikrar hedefine tabi tutmaya hazır olmaktan çok uzaktır. Muhtemelen politikacılar bu seçimle yüzleşmek istemeden önce bir veya iki çöküşe, birkaç büyük döviz kuru rahatsızlığına, birkaç hisse senedi piyasası çökmesine ihtiyaç duyacak. Bu, 2018'in çok ötesine uzanan bir yama ve ardından karışık bir acil durum sırasına işaret ediyor. Zaman geçtikçe, para istikrarsızlığının neden olduğu hasar giderek artacak ve onu hayata geçirecek eğilimler parasal birlik ütopyasını mümkün kılıyor.

Yeni Dünya Ekonomisi

1970'lerin başından bu yana dünya ekonomisindeki en büyük değişiklik, döviz kurlarını yönlendiren güç olarak para akışının mal ticaretinin yerini almasıdır. Dünya finans piyasalarının sürekli birleşmesinin bir sonucu olarak, ulusal ekonomi politikalarındaki farklılıklar faiz oranlarını (veya gelecekteki faiz oranları beklentilerini) hafifçe bozabilir, hatta bir ülkeden diğerine büyük miktarda finansal varlık devri gerektirebilir. Bu transferler, ticaret gelirlerinin farklı para birimleri için talep ve arz etkisinde ve dolayısıyla döviz kurları etkisinde dalgalanmaktadır. Telekomünikasyon teknolojisi ilerlemeye devam ettikçe, bu işlemler daha ucuz ve daha hızlı olacaktır. Plansız iktisat politikaları ile para birimleri daha da değişken olabilir.

Ayrıca, bu eğilim uluslararası ticaret için sürekli ilerleyen bir başka fırsat. Bu da gelişen teknolojinin armağanıdır. Düşen nakliye masrafları, aralarında binlerce kilometre bulunan ülkelerin birbirlerinin pazarlarında rekabet etmesini kolaylaştıracak. Fiyatların tek bir para birimine dönüştürülmesinden sonra, fiyat yasası (bir malın her yerde aynı maliyete sahip olması gerektiği) kendini giderek daha çok gösterecektir. Politikacılar izin verirken, ulusal ekonomiler finansal piyasalarını takip

edecek ve dış dünyaya daha açık hale gelecekler. Bu, mallara uygulandığı kadar aynı zamanda teknolojinin yeteneğiyle işçinin emeğini teslim ettiği noktadan ayrılacak şekilde işgücüne de uygulanacak. Hintli bilgisayar operatörleri New York'luların maaş çeklerini hazırlayacaklar.

Bütün bu yollarla ulusal ekonomik sınırlar yavaş yavaş çözülmektedir. Eğilim devam ettikçe, en azından ana sanayi ülkeleri arasında para birliğinin cazibesi döviz tüccarları ve hükümetler hariç herkes için karşı konulmaz görünecektir. Anka kuşağında, görelî fiyatlarda kaymalara yönelik ekonomik düzenleme, bugün büyük ekonomilerdeki farklı bölgeler arasında olduğu gibi, sorunsuz ve otomatik olarak gerçekleşecektir. Kur riskinin olmayışı ticaret, yatırım ve istihdamı artıracaktır. Anka kuşağı ulusal hükümetler üzerinde sıkı kısıtlamalar getirecektir. Örneğin, ulusal bir para politikası diye bir şey olmayacak.

Dünya anka kuşu arzı, belki de IMF'den gelen yeni bir merkez bankası tarafından sabitlenecekti. Dünya enflasyon oranı ve dolayısıyla dar marjlar dahilinde, her ulus, enflasyon oranından kendisi sorumlu olacaktı. Her ülke, talepteki geçici düşüşleri telafi etmek için vergi ve kamu harcamalarını kullanabilir, ancak bütçe açığını finanse etmek için para basmak yerine borç alması gerekir. Enflasyon vergisine başvurmaksızın, hükümetler ve alacaklıları borçlanma ve borç verme planlarını bugün olduğundan daha dikkatli bir şekilde yargılamak zorunda kalacaklardı. Bu büyük bir ekonomik egemenlik kaybı anlamına gelir, ancak anka kuşunu bu kadar çekici yapan eğilimler her durumda o egemenliği ortadan kaldırıyor. Az ya da çok düşük oranlı döviz kurları dünyasında bile, bireysel hükümetler politika bağımsızlıklarının düşmanca bir dış dünya tarafından kontrol edildiğini gördüler.

Gelecek yüzyıl yaklaştıkça, dünyayı ekonomik birleşmeye doğru iten doğal güçler hükümetlere geniş bir seçenek sunacak. Bu süreci izleyebilir veya engel olabilirler. Anka kuşunun yolunu hazırlamak, politika üzerinde daha az sahte anlaşmalar ve daha çok gerçekleşen anlaşmalar anlamına gelecektir. Bu, mevcut ulusal paraların yanında uluslararası bir paranın özel sektör kullanımına izin vermek ve daha sonra aktif olarak teşvik etmek anlamına gelecektir. Bu, insanların tam para birliğine geçmesi için cüzdanlarıyla oy kullanmasına izin verecektir. Anka kuşu, tıpkı Özel Çekme Haklarının bugün olduğu gibi, ulusal para birimlerinin kokteyli olarak

başlayacaktır. Bununla birlikte, zaman içinde, ulusal para birimlerine karşı değeri önemli olmayacaktır, çünkü insanlar bunu rahatlığı ve satın alma gücünün istikrarı için seçeceklerdir.

Politika yapıcı bağımsızlığı korumanın alternatifi ticaret ve sermaye akışı üzerine gerçek anlamda acımasız kontrollerin yeni tomurcuklarını içerecektir. Bu ders hükümetlere muhteşem bir zaman sunuyor. Döviz kuru hareketlerini yönetebilir, engelleme olmaksızın para ve maliye politikasını uygulayabilir ve sonuçta ortaya çıkan enflasyon patlamalarıyla, fiyat ve gelir politikalarıyla mücadele edebilirler. Bu büyümeyi engelleyen bir ihtimal. Anka kuşu 2018 civarında gelecek ve o geldiğinde, karşılayın.

“Get Ready For A World Currency”

Kaynak: The Economist, 01/09/88, Vol. 306, ss. 9-10

çev: Meltem TEKİNAY