

## BÖLÜM 2

### KRİPTO PARA VE DÖVİZ TÜRLERİNİN BİST-100 ENDEKSİ ÜZERİNE ETKİLERİNİN İNCELENMESİ

Dr. Öğr. Üyesi Enes FİLİZ<sup>1</sup>

DOI: <https://dx.doi.org/10.5281/zenodo.8417324>

---

<sup>1</sup> Dr. Öğr. Üyesi, Balıkesir Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, Balıkesir (ORCID: 0000-0002-8006-9467)



## GİRİŞ

Küreselleşen dünya ekonomisi ile birlikte hem para piyasalarında hem de ekonomi yönetimlerinde farklılıklar ortaya çıkmaya başlamıştır. Piyasaların, ülkeler arasında yapılan her görüşmenin ya da yapılan her konuşmanın etkisinde kaldığı bir gerçektir. Son zamanlarda oldukça gündem olan ve kullanılmaya başlayan kripto paralar hem piyasalarda hem de kişilerin bireysel olarak yatırımlarında dikkat çekmektedir. Bunun yanı sıra halihazırda kullanımda olan döviz türleri de insanlar ve ülkeler için önemli bir noktada kalmaya devam etmektedir. Kripto paralar belki de yakın gelecekte daha da ön plana çıkarak dövizin yerini alabilir mi bunu zaman gösterecektir. Kripto para verileri genel olarak büyük veriler olduğunda topluluk öğrenme algoritmaları ya da makine öğrenmesi algoritmaları ile analizlerinin yapılması uygun olacaktır.

Popülerliği günden güne artan kripto para piyasası günümüzde çalışmalara sıklıkla konu olmaya başlamıştır. Literatürdeki çalışmaları incelendiğinde kripto para ile ilgili farklı çalışmalar yapıldığı görülmüştür. . Rahouti vd. (2018), çalışmalarında bitcoin güvenliği çözümü için makine öğrenmesi algoritmalarından yararlanmışlardır. Kolla (2020), kripto paranın geleceğe yönelik tahmini için hibrit derin öğrenme önermiştir. Khedr vd. (2021), 2010 ile 2020 yılları arasında kadar kripto para birimi fiyat tahmini alanında yapılan çalışmaların bir özetini ortaya koymuşlardır. Tiwari vd. (2021, Ekim), çalışmalarında makine öğrenmesi algoritmalarını kullanarak Bitcoin fiyatlarının nasıl tahmin edilebileceğini açıklamışlardır. Shahbazi & Byun (2022), çalışmalarında kripto paranın risk durumu için Hiyerarşik Risk Paritesi ve denetimsiz makine öğrenimi yöntemini kullanmışlardır. Shukla vd. (2023), çalışmalarında regresyon analizi kullanarak gelecekteki hem TRX fiyatını hem de bir sonraki gün için kâr mı ya da zarar mı olacağını tahmin etmek için etkili bir sınıflandırıcı oluşturmayı ve son olarak işlem başarı oranını tahmin etmeyi amaçlamışlardır. Hajek vd. (2023), Bitcoin fiyatlarını tahmin etmek için kripto para biriminin ticaret verilerini ve destek vektör regresyonunu (BSVR) kullanarak yeni bir tahmin modeli önermişlerdir.

Kripto para güvenliği için öğrenme algoritmaları kullanılarak çeşitli çalışmalar yapılmıştır (Alarab vd., 2020, Haziran; Jatoth, vd., 2021; Pettersson Ruiz & Angelis, 2022; Saxena, vd., 2023). Ayrıca kripto para ve Bist-100 endeksi arasındaki ilişkilerde bazı çalışmalarda incelenmiştir

(Soyaslan, 2020; Tunçel & Gürsoy, 2020; Demirel & Hazar, 2021; Ustaoglu, 2022; Gülcü & Kıtık 2022).

Yapılan araştırmalar çerçevesinde çalışma, Bist-100 endeksinin yönüne odaklanacaktır. Bu bağlamda iki temel araştırma sorusu ile karşılaşılabilecektir. Birincisi Bist-100 endeksinin yönüne kripto para ve dövizlerin etki edip etmediğini incelemek; ikincisi de eğer bir etki varsa bu etkilerin kripto paradan mı ya da dövizden mi kaynaklandığını belirlemek olacaktır. Bu temel araştırma sorularının yanı sıra analizlerde yararlanılacak olan Hold-out yönteminde kullanılacak olan farklı oranlardan hangi oranın en iyi sonuç verdiğini bulmak amaçlanmıştır.

## 1. MATERYAL METOD

### 1.1. Veri Seti

Çalışmanın odaklandığı temel araştırma soruları çerçevesinde Bist-100 endeksinin yönünün sınıflandırılması belirlemek için kripto para ve dövizlerden yararlanılacaktır. İşlem hacmi en yüksek 18 kripto para ve 18 döviz türü seçilmiştir. 01.01.2020-01.07.2023 tarihleri arasındaki değerler baz alınmıştır. Investing.com internet sitesinden veriler derlenmiş, düzenlenmiş ve analize uygun hale getirilmiştir. Veriler o günkü kapanış değerlerine göre toplanmıştır. Ayrıca standartlaştırma işlemi doğrultusunda tüm değişkenler bir önceki güne göre artış sağlamışsa 1; azalış göstermişse 0 olarak kodlanmıştır. Tüm değişkenler Tablo 1’de gösterilmiştir.

**Tablo 1:** Çalışmada kullanılan tüm değişkenler

<i>Bağımsız Değişkenler</i>		<i>Bağımlı Değişken</i>
<i>Kripto Para</i>	<i>Döviz</i>	
Tether	Amerikan Doları	Bist-100
Bitcoin	Euro	
Ethereum	İngiliz Sterlini	
Usd Coin	İsviçre Fransı	
TrueUSD	Kanada Doları	
Litecoin	Birleşik Arap Emirlikleri Dirhemi	
Bitcoin Cash	Avustralya Doları	
XRP	Brezilya Reali	
Bnb	Çin Yuanı	
Dogecoin	İsrail Şekeli	
Ethereum classic	Hindistan Rupisi	
Chainlink	Meksika Pesosu	
Waves	Norveç Kronu	
Verge	Rus Rublesi	
Tron	Suudi Arabistan Riyali	
Filecoin	Japon Yeni	
Storj	Hong Kong Doları	
EOS	Kuveyt Dinarı	

## 1.2. Yöntemler

Bist-100 endeksinin yönünün sınıflandırılmasında kripto para ve dövizlerin etkisini incelemek amacıyla topluluk öğrenme algoritmalarından olan Adaptive Boosting (AdaBoost) algoritması kullanılacaktır. Bu algoritmanın bileşeni olarak lojistik regresyon algoritması seçilmiştir. Ayrıca Simetrik Belirsiz Öznitelik Değerlendirmesi algoritması yardımıyla Bist-100 endeksinin yönüne etki eden kripto para ve döviz türleri belirlenecektir.

*Adaptive Boosting (AdaBoost) algoritması*, Topluluk öğrenme algoritmalarından olan bu algoritma, sınıflandırma algoritmasının performansını arttırmayı amaçlamaktadır (Schwenk & Bengio, 1997). AdaBoost altında yatan sınıflandırma algoritması yardımıyla farklı sınıflandırma algoritmaları tarafından yanlış sınıflandırılan örneklere odaklanarak çalışmaktadır (Margineantu & Dietterich, 1997). Bu çalışmada da belirtildiği gibi alt kısımda çalışacak algoritma olarak lojistik regresyon algoritması kullanılacaktır.

*Lojistik Regresyon (LR)*, standart regresyon modellerine benzer şekilde bağımlı değişken ve bağımsız değişkenler arasındaki durumu ortaya çıkarmak için kullanılmakta; bağımlı değişkenin 0 veya 1 değerine sahip olduğu durumlarda faydalanılmaktadır (Hosmer vd., 2013). Lojistik fonksiyonun formülü aşağıdaki biçimde yazılabilir;

$$g(z) = \frac{1}{1 + e^{-z}}, \mathcal{R} \rightarrow [0,1]$$

Burada,  $g(z)$  değerinin alabileceği değerler 0 ile 1 arasındadır. Almış olduğu değer 0,5'ten büyük ise 1'e yakınsadığı, küçük ise 0'a yakınsadığını söylemek mümkündür (Balaban ve Kartal, 2015).

*Odds oranı*, bir olayın gerçekleşebilmesi ile gerçekleşmemesi olasılıkları arasındaki ilişkinin bir ölçüsüdür. Odds oranı, genel olarak tüm çalışmalarda özellikle vaka kontrol çalışmalarında sıklıkla kullanılmaktadır. Odds oranı ne kadar büyük olursa, olayın gerçekleşme olasılığı da o kadar büyük olur. Birden küçük olan odds oranları, olayın gerçekleşme oranının daha küçük olduğunu göstermektedir (Davies vd., 1998).

Çalışmanın temel araştırma noktası olan Bist-100 endeksinin yönüne etki eden kripto para veya döviz türlerini bulabilmek için Simetrik Belirsiz Öznitelik Değerlendirmesi (Symmetrical Uncert Attribute Eval) algoritmasından yararlanılacaktır.

*Simetrik Belirsiz Öznitelik Değerlendirmesi*, veri setindeki simetriklik durumuna göre çalışma prensibine sahip bu algoritma değerlere 0 ve 1 değerini atayarak o sınıfa ait olup olmadığını belirlemek için kullanılmaktadır. Ayrıca simetriklik durumu, değişkenler arasındaki korelasyonları belirlemek için de kullanılabilir (Press vd., 1986; Liu & Motoda, 2012).

### 1.3. Hold-out yöntemi

Çalışmanın odak noktalarını çözümlenebilmek amacıyla kullanılacak olan topluluk öğrenme algoritmalarının çalışma prensiplerinin temelini oluşturan bazı yöntemler mevcuttur. Bu yöntemlerde temel nokta eğitim veri seti ve test veri setinin ayrımıdır. Hold-out yöntemi de bu yöntemlerden biridir. Çalışmada kullanılacak bu yöntemde belirlenen oranlar dahilinde eğitim ve test veri seti ayrımı yapılır. Örneğin bir veri setinde %60 eğitim veri seti olarak ayrılırsa, kalan %40 test veri seti olarak işleme dahil edilmektedir. Bu çalışmada tek bir oran yerine farklı oranlar kullanılacak ve bu oranlar arasında en iyi sonuç veren oran belirlenmeye çalışılacaktır.

### 1.4. Sınıflandırma Kriterleri

Çalışmada Bist-100 endeksinin yönünün sınıflandırma başarılarının belirlenebilmesi bazı kriterlerin kullanılması gerekmektedir. Bu kriterler yardımı ile sonuçlar analiz edilecektir. Kullanılacak olan kriterler DP oranı, YP oranı, F-ölçütü ve Ortalama mutlak hata (Mean Absolute Error-MAE) kriterleridir.

*DP oranı*, en temel sınıflandırma başarısını ölçen kriterlerdendir. Doğru sınıflandırılmış pozitif verilerin, modeldeki tüm pozitif veri sayısına oranlanmasıyla hesaplanmaktadır. Yüksek olan DP oranı değerinin daha iyi sınıflandırma başarısı gösterdiği söylenebilir. *YP oranı*, DP oranının aksine daha düşük değer alması istenen sınıflandırma kriteridir. Aslında negatif olan ancak pozitif olarak sınıflandırılmış olan verilerin tüm negatif veri sayısına oranlanması ile elde edilmektedir. *F-ölçütü*, DP oranına benzer şekilde yüksek değer alması beklenmektedir. Doğru sınıflandırılmış olan pozitif verilerin toplam pozitif verilerin sayısına oranı ve DP oranının harmonik ortalaması ile belirlenmektedir. *MAE*, bir modelde tahmin edilen değerler ile gözlenen değerler arasındaki farkları ortaya çıkarmaya yardımcı olan sınıflandırma kriteridir. Bu değer düşük değer vermesi sınıflandırma açısından daha iyi olduğunu göstermektedir.

## 2. UYGULAMA

Kripto para ve döviz türlerinin Bist-100 endeksinin yönüne etki edip etmediğini belirlemek amacıyla çalışmada topluluk öğrenme algoritması AdaBoost/LR kullanılmıştır. Ayrıca Hold-out yönteminde kullanılacak en uygun belirlenmiştir. Bu bağlamda çalışmada öncelikler tüm değişkenler kullanılmış ve sınıflandırma başarıları elde edilmiştir. Ayrıca odds oranları ve katsayılar bulunmuştur. Ardından Bist-100 endeksinin yönüne etki eden kripto para veya döviz türlerinin belirlenmesi için Simetrik Belirsiz Öznitelik Değerlendirmesi algoritması kullanılmıştır. Bu yöntem ile hem etkili değişkenler belirlenmiş hem de etki oranları ortaya konmuştur. Son olarak etkili değişkenler yardımıyla Bist-100 endeksinin yönünün sınıflandırma başarıları elde edilmiş ve sonuçlar sunulmuştur. Yine burada da odds oranları ve katsayılar belirlenmiştir.

## 3. BULGULAR

Çalışmanın araştırma sorularına yönelik olarak kurgulanan uygulama sonucunda bulgular elde edilmiştir. İlk olarak Bist-100 endeksinin yönünün sınıflandırma başarıları tüm değişkenler yardımıyla topluluk öğrenme algoritması AdaBoost/LR ile belirlenmiş ve sonuçlar Tablo 2’de verilmiştir.

**Tablo 2:** Çalışmada kullanılan tüm değişkenler yardımıyla elde edilen sınıflandırma başarıları

<i>Hold-Out Oranlar</i>	<i>DP oranı</i>	<i>YP oranı</i>	<i>F-ölçütü</i>	<i>MAE</i>
%50	0,586	0,480	0,561	0,4698
%65	0,562	0,515	0,543	0,4774
%80	0,576	0,494	0,566	0,4745
%85	0,589	0,477	0,573	0,4712
%90	0,616	0,427	0,591	0,4647
<b>%95</b>	<b>0,750</b>	<b>0,317</b>	<b>0,747</b>	<b>0,4272</b>

Tablo 2’ye göre, DP oranı en yüksek değer %95 oranıyla 0,750 olarak belirlenmiştir. Ayrıca YP oranı değeri (0,317), F-ölçütü değeri (0,747) ve MAE değeri (0,4272) bu sonucu desteklemektedir. İkinci en yüksek değer ise %90 oranıyla 0,616 olarak bulunmuştur.

Tablo 3’te ise uygulama bölümünde belirtilmiş olan katsayılar ve odds oranları gösterilmiştir.

**Tablo 3:** Çalışmada kullanılan tüm değişkenler için katsayılar ve odds oranları

<i>Katsayılar</i>		<i>Odds Oranları</i>	
Tether	0.2244	Tether	0.079
Bitcoin	0.1524	Bitcoin	0.026
Ethereum	0.1751	Ethereum	0.0479
Usd Coin	0.0232	Usd Coin	0.0309
TrueUSD	0.1553	TrueUSD	0.045
Litecoin	-0.5521	Litecoin	0.1556
Bitcoin Cash	0.3659	Bitcoin Cash	0.1925
XRP	-0.3741	XRP	0.1007
Bnb	-0.0179	Bnb	0.0148
Dogecoin	0.0375	Dogecoin	0.0258
Ethereum classic	0.0714	Ethereum classic	0.0333
Chainlink	-0.1075	Chainlink	0.033
Waves	0.1865	Waves	0.0638
Verge	0.0405	Verge	0.0123
Tron	-0.213	Tron	0.1027
Filecoin	-0.006	Filecoin	0.014
Storj	0.0689	Storj	0.0113
EOS	0.0077	EOS	0.0247
Amerikan Doları	0.2354	Amerikan Doları	0.0521
Euro	0.3299	Euro	0.0882
İngiliz Sterlini	-0,2378	İngiliz Sterlini	0.0544
İsviçre Fransı	0,4209	İsviçre Fransı	0.1552
Kanada Doları	-0.5701	Kanada Doları	0.2297
B. A. E. Dirhemi	-0.5798	B. A. E. Dirhemi	0.3528
Avustralya Doları	0.0137	Avustralya Doları	0.0284
Brezilya Reali	-0.136	Brezilya Reali	0.0269
Çin Yuanı	-0.076	Çin Yuanı	0.0049
İsrail Şekli	-0.3633	İsrail Şekli	0.1242
Hindistan Rupisi	-0.0996	Hindistan Rupisi	0.0095
Meksika Pesosu	-0.1266	Meksika Pesosu	0.0863
Norveç Kronu	-0.2157	Norveç Kronu	0.0296
Rus Rublesi	0.0716	Rus Rublesi	0.0187
Suudi Arabistan Riyali	0.8111	Suudi Arabistan Riyali	0.5177
Japon Yeni	0.2803	Japon Yeni	0.192
Hong Kong Doları	0.1486	Hong Kong Doları	0.0287
Kuveyt Dinarı	0.5379	Kuveyt Dinarı	0.1078

Tablo 3 incelendiğinde çalışmada kullanılan değişkenlerin modeldeki katsayıları gösterilmiştir. Bu bağlamda odds oranları da verilmiştir. Odds oranı yüksek olan değerler için başarılı sınıflandırma sonuçlarına daha fazla katkı sağladığı söylenebilir. Suudi Arabistan Riyali (0,5177) ve B.A.E. Dirhemi (0,3528) en yüksek odds oranına sahip değişkenler olarak belirlenmişlerdir.

Tüm değişkenler kullanılarak sınıflandırma başarıları elde edildikten sonra Bist-100 endeksinin yönüne etki eden kripto para veya döviz türlerinin belirlenmesi amacıyla Simetrik Belirsiz Öznitelik Değerlendirmesi algoritması kullanılmış ve sonuçları Tablo 4'te sunulmuştur.

**Tablo 4:** Bist-100 endeksinin sınıflandırma başarısına etki eden değişkenler ve etki oranları

<i>Etkili Değişkenler</i>	<i>Etki Oranları</i>
Kuveyt Dinarı	0.01585
Suudi Arabistan Riyali	0.01569
B. A. E. Dirhemi	0.01324
Japon Yeni	0.01068
İsviçre Frangı	0.0089
XRP	0.00637
Litecoin	0.00585
Amerikan Doları	0.00576

Tablo 4'e göre, 6 döviz türünün ve 2 kripto paranın Bist-100 endeksinin yönünün sınıflandırılmasında etkin rol oynadığı belirlenmiştir. Kuveyt Dinarı döviz türleri arasında en etkin olan değişken olarak belirlenmiş (0.01585); benzer şekilde Suudi Arabistan Riyali de (0.01569) Kuveyt Dinarı'na yakın sonuç göstermiştir. Kripto paralar arasında ise en etkin değişken olarak XRP (0.00637) belirlenmiştir.

Uygulama bölümünün son kısmı olan etkin değişkenler yardımı ile Bist-100 endeksinin yönünün sınıflandırma başarıları AdaBoost/LR ile belirlenmiş ve sonuçlar Tablo 5'te verilmiştir.

**Tablo 5:** Bist-100 endeksinin sınıflandırma başarısına etki eden değişkenler yardımıyla elde edilen sınıflandırma başarıları

<i>Hold-Out Oranlar</i>	<i>DP oranı</i>	<i>YP oranı</i>	<i>F-ölçütü</i>	<i>MAE</i>
%50	0,588	0,501	0,540	0,4734
%65	0,583	0,502	0,559	0,4720
%80	0,594	0,482	0,581	0,4702
%85	0,613	0,448	0,600	0,4654
%90	0,616	0,427	0,591	0,4719
<b>%95</b>	<b>0,732</b>	<b>0,349</b>	<b>0,727</b>	<b>0,4392</b>

Tablo 5'e göre, DP oranı en yüksek değer %95 oranıyla 0,732 olarak belirlenmiştir. Ayrıca YP oranı değeri (0,349), F-ölçütü değeri (0,727) ve MAE değeri (0,4392) bu sonucu desteklemektedir. İkinci en yüksek değer ise %90 oranıyla 0,616 olarak bulunmuştur.

Tablo 6’da ise yine uygulama bölümünde belirtilmiş olan katsayılar ve odds oranları etkin değişkenler için gösterilmiştir.

**Tablo 6:** Bist-100 endeksinin sınıflandırma başarısına etki eden değişkenler için katsayılar ve odds oranları

<i>Katsayılar</i>		<i>Odds Oranları</i>	
Litecoin	-0.2221	Litecoin	0.8008
XRP	-0,2441	XRP	0.7834
Amerikan Doları	0.1227	Amerikan Doları	1.1305
İsviçre Frangı	0.1106	İsviçre Frangı	1.117
B. A. E. Dirhemi	-0.5934	B. A. E. Dirhemi	0.5525
Suudi Arabistan Riyali	0.7757	Suudi Arabistan Riyali	2.1721
Japon Yeni	0.1191	Japon Yeni	1.1265
Kuveyt Dinarı	0.2805	Kuveyt Dinarı	1.3238

Tablo 6’ya göre, çalışmada kullanılan Bist-100 endeksinin yönünün sınıflandırma başarısında etkin olarak belirlenen değişkenlerin modeldeki katsayıları gösterilmiştir. Odds oranı yüksek olan değerler için başarılı sınıflandırma sonuçlarına daha fazla katkı sağladığı söylenebilir. Suudi Arabistan Riyali (2,1721) ve Kuveyt Dinarı (1,3238) en yüksek odds oranına sahip değişkenler olarak belirlenmişlerdir.

#### 4. DEĞERLENDİRME VE SONUÇ

Globalleşen dünya ekonomisi ile birlikte yapılan araştırmalar çerçevesinde çalışmanın temel araştırma sorularına yönelik olarak; Bist-100 endeksinin yönünün sınıflandırılmasında kripto para veya döviz türlerinin etkinlik gösterip göstermediği belirlenmiştir. Bu çerçevede kripto para veya döviz türlerinin hangilerinin Bist-100 endeksinin yönünün sınıflandırılmasına etki ettiği ve ne boyutta etki ettiği bulunmuştur.

Çalışmanın araştırma soruları göz önüne alındığında Bist-100 endeksinin yönüne kripto para ve dövizlerin etki edip etmediği incelenmiş ve önemli sonuçlar elde edilmiştir. Öne çıkan sonuçlar olarak öncelikle 18 kripto para türü ve 18 döviz türü olmak üzere toplam 36 bağımsız değişken yardımıyla Bist-100 endeksinin yönünün %75 oranında bilinebileceği ortaya konmuştur. Bu durumun gerçekleşebilmesi için %95 eğitim veri seti seçilerek elde edilmiştir. Ekonomik gelişmelerin her an global olarak değiştiği Dünya ekonomisinde bu sonuçların önemli bir yol gösterici olacağı düşünülmektedir.

Bir diğer araştırma sorusu olarak çalışmada belirlenen hangi kripto para veya döviz türünün Bist-100 endeksinin yönünün sınıflandırılmasına etki ettiği belirlenmiştir. Bu bağlamda öncelik olarak döviz türlerinin etkisinin

daha fazla olduğunu söylemekle birlikte, kripto para türlerinin de bu duruma etkisi olduğunu söylemek mümkündür. Döviz türlerinden Kuveyt Dinarı, Suudi Arabistan Riyali, B. A. E. Dirhemi, Japon Yeni, İsviçre Frangı, Amerikan Doları en etkili döviz türleri olarak belirlenmiştir. Kripto para türlerinden ise XRP, Litecoin etkin değişkenler olarak bulunmuştur. Ayrıca bu değişkenler yardımıyla hesaplanan sınıflandırma başarılarında büyük düşüşler görülmemiş, çoğu oranda yükselmeler görülmüştür. Bu da daha az değişken ile yine başarılı sonuçlar elde edilebileceğini göstermiştir.

Çalışmadaki diğer önemli noktada, Hold-out yöntemindeki oranlar ile hesaplamalar yapılmasıdır. Burada da sonuçlar incelendiğinden en başarılı oran olarak %95 belirlenmiştir. Bu orana en yakın değer %90 oranında bulunmuştur. Sonuç olarak yüksek eğitim seti oranlarında daha yüksek sınıflandırma başarısı elde edildiği görülmüştür. Ayrıca odds oranı yüksek olan çoğu değişkenin etkili değişken olarak seçilmiş olması bu sonucu desteklemektedir.

Çalışmanın bazı kısıtlamaları mevcuttur. Çalışma 01.01.2020-01.07.2023 tarihlerindeki işlemler göz önüne alınarak yapılmıştır. Yalnızca 18'er adet kripto para ve döviz türü için geçerlidir. Çalışmada AdaBoost/LR algoritması kullanılmıştır. Hold-out yönteminde belirlenen oranlardan yararlanılmıştır. Öznitelik seçim algoritması için sadece Simetrik Belirsiz Öznitelik Değerlendirmesi algoritması işleme dahil edilmiştir.

**KAYNAKÇA**

- Alarab, I., Prakoonwit, S., & Nacer, M. I. (2020, June). Comparative analysis using supervised learning methods for anti-money laundering in bitcoin. In Proceedings of the 2020 5th international conference on machine learning technologies (pp. 11-17).
- Balaban, M. E., & Kartal, E. (2015). Veri Madenciliği ve Makine Öğrenmesi Temel Algoritmaları ve R Dili ile Uygulamaları. Çağlayan Kitabevi, İstanbul.
- Davies, H. T. O., Crombie, I. K., & Tavakoli, M. (1998). When can odds ratios mislead?. *Bmj*, 316(7136), 989-991.
- Demirel, A. C., & Hazar, A. (2021). Kripto para değerlerine dayanılarak BİST 100 endeks hareketi tahmininde destek vektör makineleri uygulaması. *Başkent Üniversitesi Ticari Bilimler Fakültesi Dergisi*, 5(1), 27-35.
- Gülcü, Y., & Kıtık, M. A. (2022). Bitcoin Fiyatları ile Borsa İstanbul 100 Endeksi Nedensellik ve Eş Bütünleşme İlişkisi. *Fırat Üniversitesi Sosyal Bilimler Dergisi*, 32(2), 615-624.
- Hajek, P., Hikkerova, L., & Sahut, J. M. (2023). How well do investor sentiment and ensemble learning predict Bitcoin prices?. *Research in International Business and Finance*, 64, 101836.
- Hosmer Jr, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied logistic regression (Vol. 398). John Wiley & Sons.
- Jatho, C., Jain, R., Fiore, U., & Chatharasupalli, S. (2021). Improved classification of blockchain transactions using feature engineering and ensemble learning. *Future Internet*, 14(1), 16.
- Khedr, A. M., Arif, I., El-Bannany, M., Alhashmi, S. M., & Sreedharan, M. (2021). Cryptocurrency price prediction using traditional statistical and machine-learning techniques: A survey. *Intelligent Systems in Accounting, Finance and Management*, 28(1), 3-34.
- Kolla, V. R. K. (2020). Forecasting the Future of Crypto currency: A Machine Learning Approach for Price Prediction. *International Research Journal of Mathematics, Engineering and IT*, 7(12).
- Liu, H., & Motoda, H. (2012). Feature selection for knowledge discovery and data mining (Vol. 454). Springer Science & Business Media.
- Margineantu, D. D., & Dietterich, T. G. (1997, July 8–12). Pruning adaptive boosting. In D. H. Fisher (Ed.), Proceedings of the Fourteenth International Conference on Machine Learning, Nashville, TN, USA

- (pp. 211–218). Morgan Kaufmann. <https://dl.acm.org/doi/10.5555/645526.757762>
- Pettersson Ruiz, E., & Angelis, J. (2022). Combating money laundering with machine learning—applicability of supervised-learning algorithms at cryptocurrency exchanges. *Journal of Money Laundering Control*, 25(4), 766-778.
- Press, W. H., Flannery, B. P., Teukolsky, S. A., & Vetterling, W. T. (1986). *Numerical recipes: The art of scientific computing*. Cambridge University Press.
- Rahouti, M., Xiong, K., & Ghani, N. (2018). Bitcoin concepts, threats, and machine-learning security solutions. *Ieee Access*, 6, 67189-67205.
- Saxena, R., Arora, D., & Nagar, V. (2023). Efficient blockchain addresses classification through cascading ensemble learning approach. *International Journal of Electronic Security and Digital Forensics*, 15(2), 195-210.
- Schwenk, H., & Bengio, Y. (1997, December). Training methods for adaptive boosting of neural networks. In *Proceedings of the 10th International Conference on Neural Information Processing Systems*, Denver, CO, USA (pp. 647–650). MIT Press.
- Shahbazi, Z., & Byun, Y. C. (2022). Machine learning-based analysis of cryptocurrency market financial risk management. *Ieee access*, 10, 37848-37856.
- Shukla, A., Das, T. K., & Roy, S. S. (2023). TRX Cryptocurrency Profit and Transaction Success Rate Prediction Using Whale Optimization-Based Ensemble Learning Framework. *Mathematics*, 11(11), 2415.
- Soyaslan, E. (2020). Bitcoin fiyatları ile bist 100, bist banka ve bist teknoloji endeksi arasındaki ilişkinin analizi. *Fiscaoeconomia*, 4(3), 628-640.
- Tiwari, R. G., Agarwal, A. K., Kaushal, R. K., & Kumar, N. (2021, October). Prophetic analysis of bitcoin price using machine learning approaches. In *2021 6th International Conference on Signal Processing, Computing and Control (ISPCC)* (pp. 428-432). IEEE.
- Tunçel, M. B., & Gürsoy, S. (2020). Korku Endeksi (VIX), Bitcoin Fiyatları ve Bist100 Endeksi Arasındaki Nedensellik İlişkisi Üzerine Ampirik Bir Uygulama. *Elektronik Sosyal Bilimler Dergisi*, 19(76), 1999-2011.
- Ustaoglu, E. (2022). Return and Volatility Spillover Between Cryptocurrency and Stock Markets: Evidence from Turkey. *Muhasebe ve Finansman Dergisi*, (93), 117-126.

