

Farklı Zaman Serisi Modelleri İçin Önkestirim Performanslarının Karşılaştırılması: Bitcoin Örneği

Nefise FERMANCI¹, Sinan SARAÇLI^{1*}

¹ Afyon Kocatepe Üniversitesi, Fen-Edebiyat Fakültesi İstatistik Bölümü, AFYONKARAHİSAR

(Alınış / Received: 18.11.2021, Kabul / Accepted: 20.04.2022, Online Yayınlanma / Published Online: 30.04.2022)

Anahtar Kelimeler

Zaman Serileri, ARIMA, YSA, ATA Metodu, Kripto Para

Öz: Bu çalışmada saatlik ve günlük Bitcoin kripto para birimine ait veri seti kullanılarak, zaman serileri analizinde son yıllarda önemi gittikçe artan Bütünleşik Otoregresif Hareketli Ortalama (ARIMA), Yapay Sinir Ağları (YSA) ve ATA metotları yardımı ile önkestirimler yapılarak elde edilen sonuçlar karşılaştırılmıştır. Gerçek değerlere en yakın sonuç veren modeli belirlemede Hata Kareler Ortalaması (HKO) değerleri dikkate alınarak modeller karşılaştırılmıştır.

Yapılan analiz sonuçlarında sırası ile ATA, YSA ve ARIMA modellerden elde edilen sonuçların gerçeğe en yakın ve bu metotlara ait HKO değerlerinin sırası ile en küçük olduğu gözlemlenmiştir. Çalışmadan elde edilen ayrıntılı sonuçlar ilgili şekil ve çizelgelerde verilmiştir.

Comparison of Forecasting Performances for Different Time Series Models: Bitcoin Sample

Keywords

Time series, ARIMA, YSA, ATA Method, Cryptocurrency

Abstract: In this study, using dataset of hourly Bitcoin cryptocurrency, forecasting values are obtained with the help of Integrated Autoregressive Moving Average (ARIMA), Artificial Neural Networks (ANN) and ATA methods, which have become increasingly important in time series analysis in recent years. results were compared. In determining the model that gives the closest result to the real values, the mean squares of error (MSE) values are taken into account, and the models are compared.

In the analysis results, it was observed that the results obtained from the ATA, ANN and ARIMA models were the closest to the actual and the MSE values of these methods were the smallest, respectively. Detailed results obtained from the study are given in the relevant figures and tables.

1. Giriş

Kripto para birimi, güvenlik için kriptografi kullanan dijital ya da sanal bir para birimidir. Kripto paranın özüne girmeden önce paranın tanımını anlamak gerekir. Ekonomistlerin çoğu, parayı bir değiş tokuş aracı, muhasebe birimi ve değer deposu olarak tanımlamaktadır. Paranın değerli olabilmesi için; yeterince insan paraya sahip olmalı, satıcılar bunu bir ödeme şekli olarak kabul etmeli ve toplum paranın değerli olduğuna ve gelecekte de değerli kalacağına güvenmelidir gibi özelliklere sahip olması gerekir. Eski zamanlarda da eşyaların takas edilmesi alışverişin doğasını oluşturmuştur. Daha sonralarda ise sırasıyla nakit para ve kredi kartları devreye girdi, böylece paranın tanımı ve daha da önemlisi paranın güven modeli değişmiştir. Paradaki bir diğer önemli değişiklik ise işlem kolaylığı olmuştur. Altın külçelerini bir ülkeden diğer ülkelere taşıma zorluğu nakit icadının ana sebeplerinden birisi olmuştur. Daha sonraları farklı ihtiyaçlar çıkınca ve insanlar tembelleşince kredi kartları icat edilmiştir. Ancak kredi kartları hükümetin kontrolündeki parayı taşımaktadır. Dünya ülkeleri birbiriyle daha bağlantılı hale geldikçe ve insanların çıkarlarını en iyi şekilde düşünen ya da düşünmeyen

*İlgili Yazar, email: ssaracli@aku.edu.tr

otoritelerle daha fazla ilgilendikçe kripto para birimleri insanlar için değerli bir alternatif haline gelmiştir. Kriptografi kullanımı ile oluşan güvenlik özelliğinden dolayı kripto para biriminin sahtesini yapmak zordur. Bir kripto paranın tanımlayıcı özelliği ve tartışmasız en büyüleyici yanı, herhangi bir merkezi otorite tarafından çıkarılmamış olmasıdır. Bu da kripto parayı devlet müdahalesine veya manipülasyona karşı teorik olarak bağımsız kılmaktadır [1-3].

Bitcoin 2009 yılında açık kaynak kodlu olarak piyasaya çıkan ilk kripto para birimidir. Kaynak kodu açık olduğu için günümüzde mevcut Bitcoin' in orijinali ile uyumlu binlerce çeşidi vardır. Bu çeşitlerine alternatif dijital para birimleri anlamına gelen alt coin denilmektedir [3, 4].

Zaman serisi, yıllık, aylık, haftalık, günlük, saatlik gibi eşit aralıklı zaman dilimleri içinde toplanan gözlemlerin sıralanmasıyla oluşur. Zaman serileri ekonomi, mühendislik, meteoroloji, işletme, deniz bilimi, jeofizik, sağlık, eğitim vb. gibi alanlarda; firmaların harcamaları, satış ve alış rakamları, ihracat, ithalat miktarları, hisse senedi fiyatları, nüfus ölçümleri, hava sıcaklığı değerleri gibi farklı yapılarla, birçok zaman serisi türleri ortaya çıkar. Mühendislikte ve ekonomide çok karşılaşılmakla beraber özellikle istatistik alanında zaman serisi analiz yöntemleri önemli bir alanı oluşturmaktadır [5].

Bu çalışmada Bitcoin, kripto para birimi için saatlik verilerle ait zaman serileri analizi yardımı ile (Trend Analizi, ARIMA Modelleri- Box Jenkins Metodolojisi, Artificial Neural Network (Yapay Sinir Ağları (YSA), ATA Forecasting) modellenerek gelecek dönem tahminlerinin yapılmış olup, ARIMA, YSA ve ATA yöntemlerinin karşılaştırılması amaçlanmıştır.

2. Materyal ve Metot

Çalışmada kullanılmak üzere Bitcoin kripto para birimlerine ait Aralık 2020-Mart 2021 tarihleri arasındaki 3 aylık dönemi kapsayacak şekilde derlenen 2126 saatlik kapanış değerlerini içeren veri seti ile çalışılmıştır. İlgili veri seti tradingview.com sitesi üzerinden derlenmiş olup, para birimi dolar olarak ele alınmıştır. Literatürde önkestirim amaçlı kullanılan pek çok zaman serisi yöntemi mevcut olmakla beraber bu çalışmada ARIMA, YSA ve ATA metotlarından yararlanılmıştır. Uygun ARIMA, YSA ve ATA modelleri elde edildikten sonra modellerin karşılaştırılmasında HKO kriterinden yararlanılmıştır. Veri setlerinin analizlerde Eviews, MATLAB ve R Studio programlarından yararlanılmış olup R studio programında ATA metodu için geliştirilen ATAforecasting paketinden yararlanılmıştır.

Zaman serileri bir stokastik süreçtir. Durağanlık ise bu stokastik süreç ile ilgili önemli bir kavramdır. Stokastik süreç olarak bir zaman serisinin bütün özellikleri; ortalaması, varyansı, kovaryansı, ve daha yüksek dereceden momentlerinde zamana göre sistematik bir değişim mevcut değilse ya da seri dönemsel değişimlerden arınmışsa, seri durağan zaman serisi denilmektedir ve bu durum da “durağanlık” olarak adlandırılmaktadır [6, 7].

Pratikte ortaya çıktıkları şekliyle birçok zaman serisi durağan değildir. Örneğin, birçok ülkenin ekonomisi gelişiyor ve büyüyor. Bu nedenle tipik ekonomik göstergeler zaman içinde bir eğilim gösterecektir. Bu eğilim ortalamada, varyansta veya her ikisinde de olabilir. Bu tür durağan olmayan zaman serileri bazen evrimsel olarak adlandırılır. Zaman serileri analizinin pratiğinin büyük bir kısmı, durağan bir zaman serisinde gelişen bir zaman serisinin dönüşümü ile bağlantılıdır [8].

Otokorelasyon fonksiyonu, analiz edilecek seri için uygun olabilecek model veya modellerin belirlenmesinde ve seçiminde kullanılan önemli analiz araçlarından birisidir. Otokorelasyon aynı değişkenin farklı zaman aralıklarında aldığı değerlerin ilişkisinin derecesini belirler. Zamana göre art arda elde edilmiş gözlem kümesinde farklı zaman aralıklarına sahip gözlemler arasındaki ilişkinin derecesinin ölçülmesinde kullanılan katsayıya “otokorelasyon katsayısı” denir ve $\rho(k)$ ile gösterilir. Farklı değerdeki k gecikmeleri $k = 0, 1, 2, \dots, n$ için hesaplanan $\{\rho(k)\}$ ları k gecikmelerine bağlayan fonksiyona “otokorelasyon fonksiyonu” denir [6, 9]. Otokorelasyon fonksiyonu zaman serisindeki iki nokta arasındaki ilişkiyi incelemektedir. Kısmi otokorelasyon fonksiyonu ise, diğer zaman gecikmelerinin etkisini arındırarak, X_t ve X_{t-k} arasındaki ilişkinin derecesini ölçmektedir [10].

2.1. Box–Jenkins metodolojisi (B.J)

Box ve Jenkins tarafından 1970 yılında durağanlık şartını sağlamış tek değişkenli zaman serilerinin analiz süreci için geliştirilmiş ve önkestirim metodolojisinde ARIMA (otoregresif bütünleşik hareketli ortalama, autoregressive integrated moving average) modeli olarak da isimlendirilen bir yöntemdir. Durağan halde bulunan zaman serilerinin önkestirim edilmesinde en sık kullanılan ve en uygun olan yöntem Box-Jenkins metodudur [11].

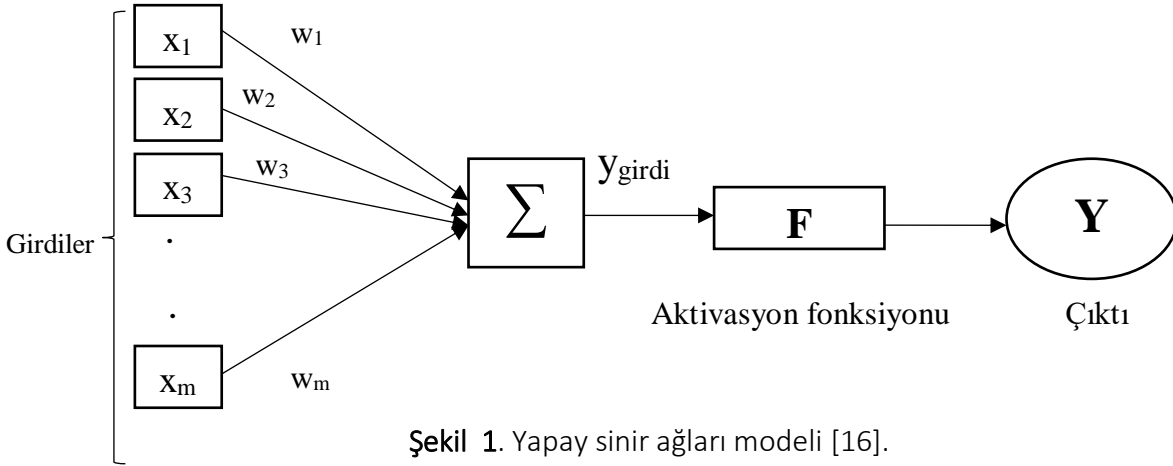
Bu yöntemin önemli varsayımları arasında eşit zaman aralıklarıyla gözlenen değerlerin oluşturduğu serinin kesikli ve durağan olması yer almaktadır. Otokoregresif (autoregressive (AR)) modelleri ve hareketli ortalama (moving average (MA))

modelleri ve bunların birleşimi olan otoregresif hareketli ortalama (autoregressive moving average ARMA) modelleri durağan süreçlere uygulanmaktadır. ARIMA modelleri durağan olmayan süreçlere uygulanan modellerdir [12].

2.2 Yapay sinir ağları (YSA)

Yapay sinir ağları, insanların beyin yapısını modelleyerek elde ettiği örnekleri kullanarak olayları öğrenen, bu olaylara tepkiler üreten bilgisayar sistemleridir. Beynin öğrenmek, ilişkilendirmek, gruplandırmak gibi işlevsel özelliklerine benzer şekilde; pek çok alanda başarılı bir şekilde uygulanabilmektedir. Örneklerden elde edilenler dahilinde kendi deneyimlerini oluşturarak sonrasında, benzer konular hakkında benzer sonuca ulaşabilirler. Yapay sinir ağları birbirine hiyerarşik olarak bağlı ve paralel olarak çalışabilen, süreç elemanları da denilen yapay hücrelerden oluşmuştur. Bu hücrelerin birbirlerine bağlandıkları ve her bağlantının bir değerinin olduğu kabul edilmektedir. Süreç elemanlarının birbirleri ile bağlanmaları sonucu oluşan ağa yapay sinir ağı adı verilmektedir [13]. YSA günümüzde istatistik, işletme, tıp, teknoloji, biyoloji, otomotiv, finans ve bankacılık, ekonomi ve mühendislik gibi pek çok alanda ve konuda karşımıza çıkmaktadır [14].

Şekil 1’de verilen ağ modelinde her bir girdi x_i ($i: 1,2, \dots, m$), w_i ($i: 1,2, \dots, m$) faktörü ile ağırlıklandırılmıştır. Her bir girdi birimi, ağırlıkları çarpılarak girdilerin toplamı hesaplanmaktadır. Bu hesaplama sonucunda elde edilen y_{girdi} F aktivasyon fonksiyonunda işlenerek çıktı olan Y ’nin elde edilmesini sağlar. Bu şekilde birçok girdi kullanılarak tek bir çıktı elde edilmiş olur.



Şekil 1. Yapay sinir ağları modeli [16].

Transfer fonksiyonu da denilen aktivasyon fonksiyonu, hücreye gelen net girdiyi ağırlıklar ile işleyerek hücrenin bu girdiyeye karşılık gelen net çıktısını belirler. Bu fonksiyon performansa etki edeceğinden doğru seçilmelidir. Transfer fonksiyonu olarak çıktıyı hesaplamada farklı formüller kullanılmaktadır [16, 17]. YSA yaklaşımında kullanılan bir algoritma olan Levenberg-Marquardt (LM) algoritması en yaygın kullanılan optimizasyon algoritmasıdır. Çok çeşitli problemlerde basit gradyan iniş ve diğer eşlenik gradyan yöntemlerinden daha iyi performans gösterir. LM algoritması geleneksel gradyan iniş ve Gauss-Newton yinelemesinin bir karışımıdır [18].

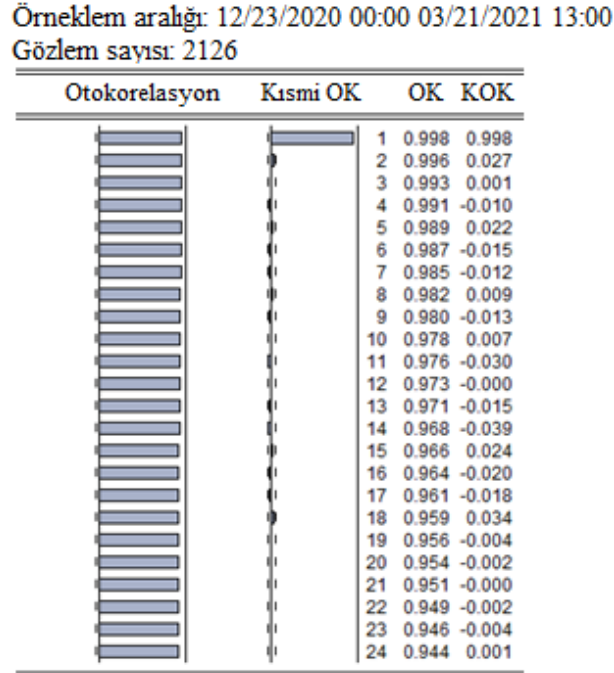
2.3 ATA Metot

Tek değişkenli zaman serileri için, modelleme ve önkestirim sürecine çok sayıda zaman serisi dahil edildiğinde, doğru ve sağlam önkestirim yöntemlerinin geliştirilmesi çok önemlidir. Model seçim algoritmalarının avantajlarına rağmen, doğru kestirim yöntemlerine hala ihtiyaç vardır. Önkestirim rekabeti, yüksek performanslı yöntemleri belirleme hedefiyle, çok sayıda zaman serisinin önkestirimine doğru ilerlemede önemli bir rol oynamıştır. ATA yöntemi, basitliği, kolay etkinlik sağlaması ve şaşırtıcı derecede iyi performansı ile büyük ilgi çekmiştir. ATA yöntemi mevsimsel olmayan ya da mevsimsizleştirilmenin çarpımsal klasik ayrıştırma yoluyla gerçekleştirildiği zaman serilerine uygulanabilir [19].

Üstel düzeltme (exponential smoothing (ES)), zaman serileri literatüründe en başarılı önkestirim yöntemlerinden birisi olarak duyurulsa ve basitliği nedeniyle pratikte yaygın olarak kullanılsa da doğruluğu takip edilen başlatma ve optimizasyon prosedürlerinden etkilenebilir. Ayrıca ağırlıklandırma şeması yakından incelendiğinde açıkça görülebilen bazı temel sorunlardan mustarıptır. Üstel düzeltme, geçmiş verilere ağırlık atarken önkestirime katkıda bulunabilecek veri noktalarının miktarını hesaba katamaz. ATA, düzeltmeye alternatif bir önkestirim yöntemi olarak önerilmiştir ve deneysel veriler üzerinde doğruluklar karşılaştırıldığında ES'ten daha iyi performans gösterdiği gösterilmiştir [20].


3. Bulgular

İlk olarak ARIMA modelleri için elde edilen sonuçlar ve bu sonuçlara ilişkin yorumlar aşağıda verilmektedir.



Şekil 2. Saatlik Bitcoin verisine ait korelogram

Şekil 2’de gösterilen ve saatlik Bitcoin verileri için incelenen korelogram grafiğinden yola çıkarak otokorelasyonun sifıra doğru hızlı bir şekilde değil de yavaş yavaş azalması ve değerlerin eşik değer dışında yoğunluk göstermesi serinin durağan olmadığını göstermektedir. Bunun daha net anlaşılabilmesi için serinin zaman serisi grafiği çizdirilir.



Şekil 3. Saatlik Bitcoin verisine ait zaman serisi grafiği

Serinin Şekil 3’te gösterilen grafiğine bakıldığında da serinin artan bir trende sahip olduğu görülmektedir. Ayrıca bu grafikte veri belirli bir ortlama etrafında dağılıma eğilimi göstermediği için verinin durağan olmadığı çıkarımı yapılmaktadır. Gelecek dönem önkestirimi yapılmadan önce seri durağan hale getirilmelidir. Durağanlığı belirlemek için Augmented Dickey-Fuller (ADF) testi kullanılmıştır.

Tablo 1. Saatlik Bitcoin verisine ait ADF test istatistik sonucu

	t-istatistiği	p-değeri
ADF test istatistiği	-2.71	0.2324
Anlamlılık seviyesi	%1	-3.96
	%5	-3.41
	%10	-3.12

$H_0: \delta = 0$ Seri durağan değildir.
 $H_1: \delta < 0$ Seri durağandır.

Tablo 1'e göre p-değeri=0.2324>0.05'tir. Bu durumda H_0 hipotezi reddedilemez ve serinin istatistiksel olarak %95 güvenilirlikte durağan olmadığı çıkarımı yapılır. Serinin durağan hale gelebilmesi için fark işlemi uygulanmalıdır.

Tablo 2. Birinci dereceden farkı alınmış saatlik Bitcoin verisinin ADF test istatistik sonucu

		t-istatistiği	p-değeri
ADF test istatistiği		-48.18	0.0000
Anlamlılık seviyesi	%1	-3.96	
	%5	-3.41	
	%10	-3.12	

Tablo 2'ye göre p-değeri=0.0000<0.05'tir. Bu durumda H_0 hipotezi reddedilemez ve serinin istatistiksel olarak %95 güvenilirlikte durağan hale geldiği çıkarımı yapılır.

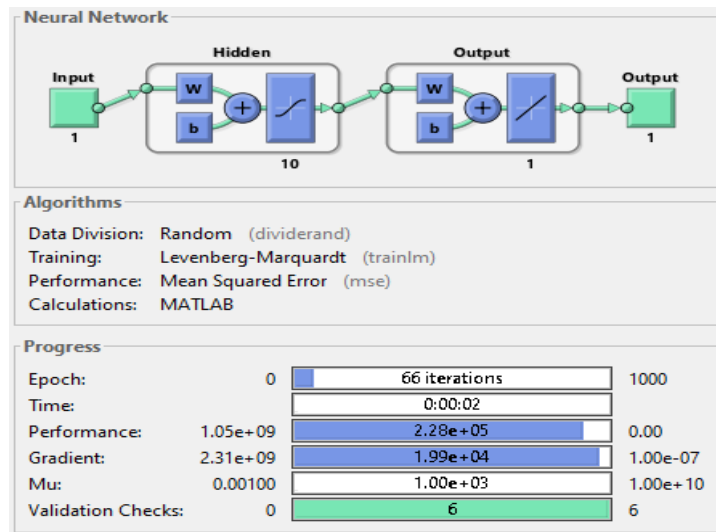
Seride durağanlık sağlandıktan sonra, durağan serinin korelogramı göz önünde bulundurularak olası modeller belirlenir ve olası modeller arasından önkestirim yapmada kullanılacak en uygun model seçilir. Olası modelleri belirlemede otokorelasyon ve kısmi otokorelasyon beraber değerlendirilmelidir. Modelin MA bileşenini belirlemede otokorelasyon, AR bileşenini belirlemede kısmi otokorelasyon kullanılır.

Olası modeller arasından modelde en fazla anlamlı katsayıya sahip, en düşük Akaike Bilgi Kriteri (AIC) ve Schwarz bilgi kriterine (SIC) sahip olan model ile en yüksek R^2 'ye sahip model uygun model olarak seçilir. Bu koşullar altında saatlik Bitcoin verisi için olası modeller arasından analize en uygun model ARIMA (13,1,1) modeli olarak belirlenmiştir. Modele ait bilgiler Tablo 3 ile verilmiştir.

Tablo 3. Saatlik Bitcoin serisine ait ARIMA modeli

Değişken	Katsayı	p-değeri
C	15.47	0.1473
AR(13)	0.07	0.0004
MA(1)	-0.05	0.0071


Ele alınan zaman serilerine ait YSA modelleri için elde edilen sonuçlar ve bu sonuçlara ilişkin yorumlar aşağıda verilmektedir.



Şekil 4. Saatlik Bitcoin verisine ait yapay sinir ağları modeli

Şekil 4 Saatlik Bitcoin verisine ait olan Yapay Sinir Ağları (YSA) modelini göstermektedir. Bu modele bakarak algoritmaya ait bilgilere, eğitim süreci bilgilerine ve model performansını değerlendirmede kullanılacak grafiklere ulaşılabilir. Bu bilgilerden yola çıkılarak model ile ilgili ağda eğitim yaparken verilerin rassal olarak alındığı, eğitim

algoritması olarak Levenberg-Marquardt algoritmasının kullanıldığı, model performansını ölçmede hata kareler ortalamasının kullanıldığını (HKO), eğitimin 66 iterasyonda tamamlandığı gibi çıkarımlar yapılabilmektedir. Literatürde birçok eğitim algoritması bulunmaktadır, bu çalışma için Levenberg-Marquardt algoritmasının seçilmesinin sebebi, diğer eğitim algoritmalarına göre daha hızlı sonuçlar üretmesidir.



Şekil 5. Modeldeki gizli katmanda eğitim, doğrulama, test ve tüm model sonuçlarına ait R değerleri

Şekil 5'te modeldeki eğitim, doğrulama ve test veri gruplarının regresyon değerleri yer almaktadır. Burada R değerleri korelasyonu ve modelin öğrenme başarısını göstermektedir. R değerleri 0.95 ve üzeridir. Yüksek olan bu R değerleri 1'e yakın olduğundan, modelde öğrenme işleminin başarılı olduğunu göstermektedir [21].

Tablo 4. Saatlik Bitcoin verileri için kurulan modellere ait HKO değerleri

Model	HKO
ARIMA	1352667.81
YSA	513277.75
ATA	205117.14

Tablo 4 ile verilen sonuçlarda, model belirlemede kullanılan HKO değerleri ARIMA, YSA ve ATA yöntemleri için karşılaştırıldığında, ATA yöntemi hatayı en aza indirerek gerçek değerlere en yakın önkestirim sonuçlarını vermiştir.

Kurulan modelden elde edilen önkestirim değerleri ile gerçek değerler arasındaki uygunluk için; ortalama mutlak hata (Mean Absolute Error (MAE)), HKO (Hata Kareler Ortalaması) ve simetrik ortalama mutlak hata (symmetric Mean Absolute Percentage Error (sMAPE)) gibi ölçütler kullanılan ölçütlerden bazılarıdır [22].

Tablo 5. ATA metot ile kripto para birimleri model belirleme

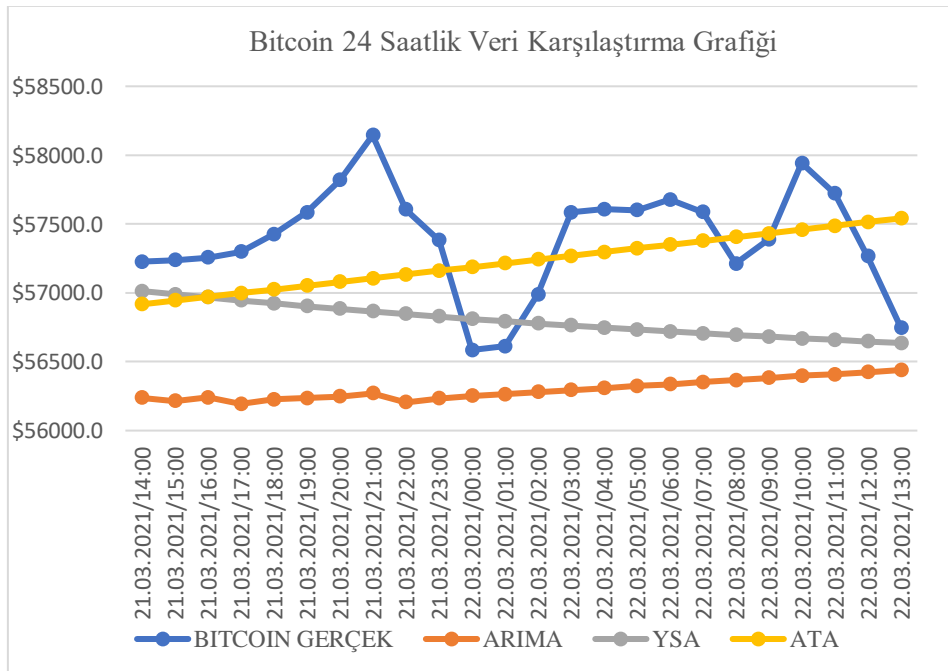
Kripto Para	Model	sMAPE
Bitcoin Günlük	Mevsimsel olmayan	3.05
	Mevsimsel	14.58

Tablo 5'te ATA metodu yardımı ile kripto para birimlerine ait kurulan mevsimsel ve mevsimsel olmayan model belirlemede elde edilen sMAPE değerleri verilmiştir. Bu değerler incelendiğinde, ilgili zaman aralığındaki günlük bitcoin değerlerini ATA metodu ile belirlemede mevsimsel olmayan modelin kullanılmasının uygun olduğu belirlenmiş ve önkestirim değerleri elde edilirken ATA metod içerisinde mevsimsel olmayan modelden yararlanılmıştır.

Tablo 6. Bitcoin için saatlik gerçek ve önkestirim değerleri

ZAMAN	BITCOIN (Gerçek)	(\$)	ARIMA (\$)	YSA (\$)	ATA (\$)
21.03.2021/14:00	57226.70		56237.97	57013.11	56916.74
21.03.2021/15:00	57238.39		56214.40	56989.95	56943.72
21.03.2021/16:00	57255.31		56240.10	56967.45	56970.71
21.03.2021/17:00	57297.08		56193.66	56945.60	56997.72
21.03.2021/18:00	57425.55		56226.28	56924.42	57024.73
21.03.2021/19:00	57583.82		56235.24	56903.89	57051.76
21.03.2021/20:00	57819.01		56247.71	56884.02	57078.80
21.03.2021/21:00	58143.87		56271.55	56864.80	57105.86
21.03.2021/22:00	57604.01		56205.57	56846.22	57132.93
21.03.2021/23:00	57381.79		56232.86	56828.27	57160.01
22.03.2021/00:00	56585.27		56253.00	56810.94	57187.10
22.03.2021/01:00	56611.91		56263.10	56794.23	57214.21
22.03.2021/02:00	56988.52		56279.71	56778.11	57241.32
22.03.2021/03:00	57584.31		56294.43	56762.58	57268.46
22.03.2021/04:00	57606.61		56307.31	56747.62	57295.60
22.03.2021/05:00	57600.00		56323.46	56733.22	57322.76
22.03.2021/06:00	57677.50		56334.84	56719.36	57349.93
22.03.2021/07:00	57585.38		56351.44	56706.03	57377.11
22.03.2021/08:00	57213.17		56366.48	56693.22	57404.31
22.03.2021/09:00	57387.73		56381.76	56680.90	57431.52
22.03.2021/10:00	57942.06		56397.78	56669.06	57458.74
22.03.2021/11:00	57720.67		56407.86	56657.69	57485.97
22.03.2021/12:00	57266.22		56424.12	56646.77	57513.22
22.03.2021/13:00	56748.00		56439.90	56636.29	57540.48

Tablo 6'da saatlik Bitcoin verileri için, gerçek değerler ve kullanılan yöntemlerden (ARIMA, YSA, ATA) elde edilen önkestirim sonuçları, Şekil 6'da ise saatlik Bitcoin verisine ait gerçek ve yöntemlerden elde edilen önkestirim değerlerinin ele alınan zaman periyodundaki seyrine ilişkin grafiği verilmiştir.



Şekil 6. Saatlik Bitcoin verisine ait gerçek-önkestirim değer karşılaştırma grafiği

4. Tartışma ve Sonuç

Zaman serileri analizi, istatistik biliminde gelecek dönemler hakkında bilgi sağlaması özelliği bakımından oldukça önemli bir yere sahip olmakla beraber, gelecek dönem ön kestirimlerinin gerçek değerlere en yakın sonuçları vermede kullanılan farklı yaklaşımlar söz konusudur. Her ne kadar zaman serileri modele katılmayan pek çok unsur ve değişkenden etkilense de bu etkileri hesaba katarak gerçeğe en yakın sonucu veren modelin belirlenmesi, gelecek dönemler için doğru önkestirim sonuçlarına bağlı olarak gerekli önlemlerin alınması ya da yatırımların yapılabilmesi bakımından da büyük önem arz etmektedir.

Önkestirim yapmak amacıyla farklı kullanılan modellerin karşılaştırılmasında farklı kriter ve yaklaşımlar olmakla beraber, ana kriter gözlem değerleri ile elde edilen kestirim değerleri arasındaki farkın genelini ifade eden hata üzerine kurulu olup bu hatanın en küçük olduğu model en iyi model olarak belirlenmektedir.

Bu çalışmada ele alınan kripto paralara ait zaman serilerinin modellenmesinde ARIMA, YSA ve ATA metotları kullanılarak, bu metotların performanslarını karşılaştırmada HKO ölçütünden yararlanılmıştır.

ARIMA modeller zaman serisi analizinde çok bilinen bir model grubu olmakla beraber, Yapay Sinir Ağları da zaman serileri analizinde kullanılan ve önemi gün geçtikçe artan bir algoritma yaklaşımı olarak karşımıza çıkmaktadır. ATA metodu ise, son zamanlarda önkestirim yapmada bilinen yöntemlere alternatif olarak ortaya çıkan ve uluslararası alanda yapılan yarışmalarda önkestirim doğruluğu yanında basitliği açısından oldukça başarılı sonuçlar vermiş olan yeni ve etkili bir zaman serisi modelleme yaklaşımıdır.

Bu çalışmada kripto para birimleri olan Bitcoin, Ethereum ve Litecoin için saatlik ve günlük veriler kullanılarak olarak ARIMA, YSA ve ATA metotları ile önkestirimler elde edilerek bu önkestirim değerleri gerçek değerlerle karşılaştırılarak en etkili metod belirlenmiştir.

Elde edilen analiz sonuçlarından da görüleceği üzere YSA'ndan elde edilen önkestirim değerleri ARIMA modellerinden elde edilen önkestirim değerlerinden gerçeğe daha yakın iken, ATA Metot aracılığı ile elde edilen önkestirim değerlerinin de YSA'dan elde edilen değerlere göre gerçeğe daha yakın olduğu belirlenmiştir.

ATA metodu son yıllarda önemi artan ve mevcut diğer yöntemlere göre daha yansız önkestirimler veren bir yaklaşım olmakla beraber, bu çalışmadan elde edilen sonuçlar G. Yapar vd. [20, 23, 24]'nin yaptığı çalışmalardan elde edilen sonuçlara benzer olup, ATA metodunun karşılaştırdığı diğer yöntemlere karşı başarısına benzer sonuçlar göstermektedir.

Kaynakça

- [1] Danial, K. 2019. Cryptocurrency Investing for Dummies. John Wiley & Sons, New Jersey, 326s.
- [2] Bunjaku, F., Trajkovska, G. O., Kacarski, M. E. 2017. Cryptocurrencies – Advantages and Disadvantages, Journal of Economics, 2(1), 31-39.
- [3] Fermancı, N. 2021. Önkestirim amaçlı kullanılan farklı yöntemlerin karşılaştırılması: kripto paralar üzerine bir uygulama. Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 111s, Afyonkarahisar.
- [4] Matharu, A. 2019. Introduction to Cryptocurrency. ss 1-8, Doukas, J. A., ed. 2019. Understanding Cryptocurrencies The Money of the Future, Business Expert Press, the United States of America, 102s.
- [5] Bölük, E. 2012. Zaman serisi modellerinin belirlenmesinde artıklara uygulanan tanı teknikleri üzerine bir çalışma. Dokuz Eylül Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 115s, İzmir.
- [6] Duru, Ö. 2007. Zaman serileri analizinde ARIMA modelleri ve bir uygulama. İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Ekonometri Anabilim Dalı, Yüksek Lisans Tezi, 92s, İstanbul.
- [7] Tüzen, M. F. 2012. Türkiye turizm gelirinin öngörüsünde zaman serilerinin bileşenlerine ayrıştırılarak yapay sinir ağları ve Box-Jenkins yöntemleri ile karşılaştırmalı analizi. Kafkas Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 139s, Kars.
- [8] Fuller, W. A. 1996. Introduction to Statistical Time Series. John Wiley & Sons Inc., Canada, 698s.
- [9] Özmen, A. 1986. Zaman serisi analizinde Box-Jenkins yöntemi ve banka mevduat önkestiriminde uygulama denemesi. Anadolu Üniversitesi, Sosyal Bilimler Enstitüsü, Doktora Tezi, 156s, Eskişehir.
- [10] Oğhan, S. 2010. Zaman serisi analiz yöntemlerinin karşılaştırılması. Ege Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 75s, İzmir.

- [11] Can, S. 2020. Rüzgâr türbinleri kullanılarak üretilen elektrik enerjisi miktarının zaman serileri ile analizi ve uygulaması. İskenderun Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 87s, İskenderun.
- [12] Şenyüz, M. 2019. Türkiye'deki organik tarım ürünlerinin zaman serileri ile analizi. İstanbul Üniversitesi, Sosyal Bilimler Enstitüsü, Yüksek Lisans Tezi, 69s, İstanbul.
- [13] Uslu, Ç. S. 2011. Zaman serisi analizi ile yapay sinir ağları kestirimlerinin karşılaştırılması. Mimar Sinan Güzel Sanatlar Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 59s, İstanbul.
- [14] Keskenler, M. F., Keskenler, E. F. 2017. Geçmişten Günümüze Yapay Sinir Ağları ve Tarihçesi, *Takvim-i Vekayi*, 5(2), 8–18.
- [15] Ansarı, H. 2020. Artificial Neural Network: Learn About Electronics. Independently Publisher, the United States of America, 93s.
- [16] Özdemir, Ö. 2008. Zaman serisi modellemesinde yapay sinir ağlarının kullanımı ve bir uygulama. Anadolu Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 110s, Eskişehir.
- [17] Öztürk, K., Şahin, M. E. 2018. Yapay Sinir Ağları ve Yapay Zekâ' ya Genel Bir Bakış, *Takvim-i Vekayi*, 6(2), 25-36.
- [18] Ranganathan, A. 2004. The Levenberg- Marquardt algorithm, *Tutorial on LM Algorithm*, 11, 101-110.
- [19] Selamlar, T. H. 2017. Modelling and forecasting time series data using ATA method., *Dokuz Eylül University, Graduate School of Natural and Applied Sciences, Degree of Doctor*, 137s, İzmir.
- [20] Yapar, G., Yavuz, İ., Selamlar, H. T. 2017. Why and How Does Exponential Smoothing Fail? An in Depth Comparison of ATA-Simple and Simple Exponential Smoothing. *Turkish Journal of Forecasting*, 01(1), 30-39.
- [21] Cansız, Ö. M., Erginer, İ., Erginer, M. 2020. Trafik Kaza Sayısının ve Yaralı Sayısının Yapay Sinir Ağları ve Regresyon Yöntemleri ile Tahmini. *Osmaniye Korkut Ata Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 3(1), 29-35.
- [22] Yılmaz, E. T. 2018. Time series forecasting of intermittent demand by using ATA method and computational intelligence. *Dokuz Eylül University, Graduate School of Natural and Applied Sciences, Degree of Master*, 67s, İzmir.
- [23] Yapar, G., Çapar, S., Selamlar, H. T., Yavuz, İ. 2018. Modified Holt's Linear Trend Method. *Hacettepe Journal of Mathematics and Statistics*, 47(5), 1394-1403.
- [24] Yapar, G., Çapar, S., Yavuz, İ., Selamlar, H. T. 2019. ATA Metod. *Hacettepe Journal of Mathematics and Statistics*, 48(6), 1838–1844.