

**KRİPTO PARA GETİRİLERİ ARASINDAKİ YAYILIM
ETKİSİ: YAPAY SİNİRAĞLARI ALGORİTMASI
VE VAR MODELLERİ UYGULAMASI**

SPILOVER EFFECTS AMONG CRYPTOCURRENCY
RETURNS USING ARTIFICIAL NEURAL
NETWORK ALGORITHMS AND VAR MODELS

Önder UZKARALAR

136

KRİPTO PARA GETİRİLERİ ARASINDAKİ YAYILIM ETKİSİ: YAPAY SİNİRAĞLARI ALGORİTMASI VE VAR MODELLERİ UYGULAMASI

SPILOVER EFFECTS AMONG CRYPTOCURRENCY RETURNS USING ARTIFICIAL NEURAL NETWORK ALGORITHMS AND VAR MODELS

Önder UZKARALAR¹

Anahtar Kelimeler:

Kripto para piyasası,
Yapay sinir ağları
algoritması,
VAR modelleri,
Yayılım etkisi,

Keywords:

Cryptocurrency market,
Artificial neural network
algorithm,
VAR models,
Spillover effect,

¹ Dr. Öğr. Üyesi, Osmaniye Korkut Ata Üniversitesi, İşletme Bölümü, e-mail: onderuzkaralar@osmaniye.edu.tr, Orcid: 0000-0002-5075-3305

Alıntılanmak için/Cite as:
Uzkaralar Ö. (2026). Kripto Para Getirileri Arasındaki Yayılım Etkisi: Yapay Sinir Ağları Algoritması ve Var Modelleri Uygulaması, Çukurova Üniversitesi Sosyal Bilimler Enstitüsü Dergisi, s. 1-17

ÖZ

Menkul kıymetler borsalarında olduğu gibi kripto para piyasasında da varlıklar birbirinden etkilenmektedir. Bu anlamda, kripto para piyasasında bir varlığa gelen bir çok piyasadaki diğer varlıklara pozitif veya negatif olarak geçebilmektedir. Söz konusu etki bazen eş zamanlı olarak diğer varlıklara geçerken bazen belli bir zamana yayılarak geçmektedir. Dolayısıyla varlıklar arasındaki etkileşimin doğru bir şekilde ortaya çıkarılması yatırımcılar için kritik bir önem sahiptir. Çünkü kripto para piyasasında risk yüksek olmasına rağmen yatırımcısına yüksek getiri sağlama potansiyeline sahiptir. Bu noktadan hareketle bu çalışmada vektör otoregresif ve yapay sinir ağları algoritması modelleri birlikte kullanılarak kripto varlıklar arasındaki ilişki tahmin edilmiştir. Vektör otoregresif modeli kripto varlıklar arasındaki doğrusal ilişkiyi modellerken yapay sinir ağları algoritması doğrusal olmayan ilişkinin tahmini için kullanılmıştır. Kripto para piyasasında yüksek bir paya sahip olan Bitcoin, Ethereum, Dogecoin, Ripple ve Solana analize dahil edilmiştir. Analiz Ocak-2020 ile Ocak-2025 dönemini kapsamaktadır. Analizin ilk aşamasında kripto varlıkların getirileri arasındaki ilişkinin uzunluğu vektör otoregresif modeller yardımıyla belirlenmiştir. İkinci aşamada belirlenen gecikme sayıları göz önüne alınarak yapay sinir ağları algoritması tahmin edilmiştir. Tahmin sonuçlarına göre kripto paralara gelen bir şokun diğer kripto paralara geçmesi beş günü bulmaktadır. Yapay sinir ağları algoritması duyarlılık analizi Bitcoin → Ethereum → Solana arasında tek yönlü bir yayılım ve Ripple ↔ Dogecoin ise karşılıklı bir yayılım etkisinin olduğunu göstermektedir. Ripple ve Dogecoin arasındaki etkileşim genellikle eşzamanlıyken Bitcoin, Ethereum ve Solana arasındaki etkileşim gecikmeli olarak ortaya çıkmaktadır.

ABSTRACT

Just as in the stock market, assets in the cryptocurrency market interact with each other. In this sense, a shock to one asset in the cryptocurrency market can have a positive or negative impact on other components of the market. Sometimes this impact is spread to other assets simultaneously, but sometimes it happens over a period of time. It is therefore important for investors to understand the interactions between assets. Although the risk in the cryptocurrency market is high, it has the potential to offer high returns to its investors. This study estimates the relationship among crypto assets using vector autoregressive and artificial neural network algorithm models. While the vector autoregressive method modelled the linear relationship between crypto assets, the artificial neural network algorithm was used to estimate the non-linear relationship. Bitcoin, Ethereum, Dogecoin, Ripple and Solana, which have a high share of the cryptocurrency market, were included in the analysis. The analysis covers the period from January 2020 to January 2025. In the first stage of the analysis, the length of the relationship between the returns of the crypto assets was determined using vector autoregressive method. In the second stage, the artificial neural network algorithm was estimated taking into account the specified number of lags. According to the results of the estimation, it takes five days for a shock in cryptocurrencies to be transmitted to other cryptocurrencies. The sensitivity analysis of the artificial neural network algorithm shows that there is a unidirectional spillover effect between Bitcoin → Ethereum → Solana and a bidirectional spillover effect between Ripple ↔ Dogecoin. The interaction between Ripple ↔ Dogecoin tends to occur simultaneously, while the interaction between Bitcoin ↔ Ethereum ↔ Solana tend to emerge with a time lag.

GİRİŞ

Bireyler farklı yatırım araçlarını kullanarak ellerindeki tasarruflarını arttırmayı hedeflemektedir. Bu hedef, bireylerin yalnızca finansal refahlarını arttırmaya yönelik değil aynı zamanda geleceklerine dair belirsizlikleri yönetme isteklerini de içermektedir. Bireysel yatırımcı bu anlamda vadeli mevduat, para piyasası fonları, hazine bonoları, devlet tahvilleri, şirket tahvilleri, kira sertifikaları, hisse senetleri, yatırım fonları, emeklilik fonları, emtialar, vadeli işlemler gibi çok geniş bir yatırım aracı yelpazesi kullanmaktadır. Söz konusu araçların her biri; likidite düzeyi, vade yapısı, düzenleyici çerçeve ve getiri potansiyeli bakımından birbirinden farklı risk-getiri potansiyelleri sunarak yatırımcılara esnek bir yatırım alanı sunmaktadır. Yatırımcı bu araçlardan birine veya birkaçına yatırım yaparak maksimum getiri arayışındayken riskini de minimum seviyede tutmayı amaçlamaktadır. Dolayısıyla çeşitlendirme yoluna giderek üstlendiği yatırım riskini varlıklar arasında yaymayı amaçlamaktadır. Yatırımcı çeşitlendirmeyi birden çok piyasa aracını kullanarak yapabilmektedir. Fakat bu piyasalarda yatırım yaparken bir otoritenin koyduğu kurallara tabidir. Bu otorite piyasa bütünlüğünü sağlamak, yatırımcıyı hileli uygulamalardan korumak ve sistemik riski sınırlamak adına kritik bir rol üstlenmektedir. Tüm dünya ülkelerinde bu “geleneksel” piyasalar genellikle devlet kurumu gözetiminde yapılmaktadır ve düzenleyici rolü nedeniyle yatırımcılar otoriteye bir ödeme yapmak zorundadır. Yatırımcı açısından düzenleyici bir otoritenin varlığı bir dizi avantaj sağlasa da küreselleşen dünyada merkezi bağımlılık ve sansür riski, yavaş işlem hızı, işlem maliyeti, uluslararası ödemeler, açıklık ve şeffaflık, enflasyon ve para birimi değerlerindeki düşüşler, yüksek sınır ötesi işlem maliyetleri gibi faktörler yeni bir ihtiyacın ortaya çıkmasına neden olmuştur. Bu anlamda, özellikle 2008 küresel krizi sonrası dönem hem bireysel yatırımcılar hem de kurumlar açısından yeni bir “ödeme ve yatırım” sürecinin başlangıcı olmuştur ve kriz dönemindeki genişleyici para politikaları yatırımcıların alternatif arayışını hızlandırmıştır. Sonuç olarak, merkezi otoriteden bağımsız, 7/24 hızlı işlem olanağı tanıyan, çok düşük işlem maliyetine sahip kripto teknolojisi tanıtılmıştır. Blokzincir temeli üzerine inşa edilen bu teknoloji, dağıtık defter yapısı sayesinde işlemleri değiştirilemez biçimde

kaydederek güven unsurunu bir merkezi otoriteden yazılım katmanına taşımıştır. Sonuç olarak temelleri daha önceye dayanan fakat 2008 yılından sonra hayata geçen ve on beş yıllık sürede neredeyse dünya nüfusunun tamamına ulaşan blokzincir teknoloji yeni bir dönem başlatmıştır.

Bitcoin söz konusu yeni dönemin başlangıç noktası olmuştur. Bu anlamda Bitcoin, ilk olarak 1998 yılında Wei Dai tarafından cypherpunks posta listesinde tanımlanan ve merkezi bir otorite yerine yaratımını ve işlemlerini kontrol etmek için kriptografi kullanan yeni bir para biçimi fikrini öne süren “kripto para” adı verilen bir kavramın ilk uygulamasıdır (Dai, 1998). İlk Bitcoin spesifikasyonu 2009 yılında Satoshi Nakamoto tarafından bir kriptografi posta listesinde yayınlanmıştır. Bitcoin temelde yeni bir ödeme sistemi ve tamamen dijital bir para sağlayan bir mutabakat ağıdır (Nakamoto, 2009). Başka bir ifade ile Bitcoin fiziksel olarak üretilmeyen internetin nakdi parasıdır ve herhangi bir otorite ve ya merkeze bağlı değildir (Akçalı ve Şişmanoğlu, 2019). Bu özellik, Bitcoin’i özellikle sermaye kontrolleri veya hiperenflasyon yaşayan ekonomilerde alternatif bir değer saklama aracı hâline getirmiştir. Bitcoin aynı zamanda üç girişli defter tutma olarak isimlendirilen üçlü imzalı makbuzlar aracılığıyla güvence altına alınan ve genellikle blok zinciri aracılığıyla tutulan ortak bir işlem kaydı sunan bir muhasebe sistemi olarak görülebilir (Hambiralovic ve Karlsson, 2018; Pan, Vaughan ve Wright, 2023). Herhangi bir merkeze bağlı olmaması ve dijital ortamda çok düşük maliyetlerle işlem yapılmasına olanak tanınması Bitcoin teknolojisini devasa büyüklükte bir piyasa haline getirmiştir. Sonuç olarak 2024 yılı ortasında Bitcoin’in piyasa değeri birçok gelişmekte olan ülkenin gayrisafi yurt içi hasılasını aşmıştır (CoinMarketCap, 2024).

Bitcoin ile başlayan kripto para süreci yeni teknolojilerin de eklenmesiyle kısa bir süre içinde binlerce varlığın işlem gördüğü bir piyasa haline gelmiştir. Günümüzde bu piyasanın yaklaşık değeri 1,32 trilyon dolar seviyesindedir. Yaklaşık 650 milyar dolarlık payı ile Bitcoin teknolojisi halen dominant pozisyonudadır (Duarte, 2025). Ripple, Ethereum, Dogecoin, Tether ve Solana gibi varlıklar Bitcoin’den sonra piyasada en yüksek değere sahip dijital paralardır ve en önemli yatırım araçlarından bazılarıdır. Teknolojik alt yapıları farklı olsa da bu paralar toplam

kripto para piyasasının çok önemli bir kısmını temsil etmektedir ve bu paralarda meydana gelen bir şok piyasadaki diğer tüm dijital paraları etkileme gücüne sahiptir. Örneğin 2021’de Elon Musk’ın Dogecoin’e yönelik paylaşımları, dakikalar içinde milyonlarca dolarlık hacim yaratarak diğer altcoin fiyatlarında zincirleme hareketlere yol açmıştır. Bitcoin başta olmak üzere Ripple, Ethereum, Dogecoin ve Solana kripto varlıkları sadece diğer kripto varlıkları etkilememektedir, aynı zamanda kendi aralarında da önemli bir etkileşim halindedir. Bir kripto varlığa gelen bir şok bazen aynı gün bazen gecikmeli olarak piyasadaki diğer kripto varlıklara geçmektedir. Sonuç olarak piyasadaki öncü kripto paralara gelen herhangi bir şok zamana yayılarak diğer kripto varlıklara da geçmektedir. Karmaşık bir nedensellik ilişkisinin olduğu kripto paralar arasındaki bu yayılım etkisi bazen riskten kaçınmak bazen getiri maksimizasyonu yapmak için yatırımcılara fırsatlar sunmaktadır. Bu bağlamda bilgi aktarım mekanizmasının çözümlenmesi, portföy yönetiminde önemli avantajlar sağlama potansiyeline sahiptir. Bu nedenle kripto paralar arasındaki ilişki ağının ortaya çıkarılması ve yüksek piyasa paylarına sahip Bitcoin, Ethereum, Dogecoin, Ripple ve Solana’nın kendi aralarındaki etkileşimlerinin tahmin edilmesi önemlidir.

Kripto para piyasası geleneksel para piyasalarında olduğu gibi yüksek volatilitelere sahiptir. Bu piyasa içinde bazı varlıklar daha yüksek risk taşısa da dijital paraların tamamı doğası gereği diğer dijital paralardan belli oranda riskleri transfer etmektedir. Söz konusu durum kripto para piyasasında istatistiksel modeller kullanarak tahmin yapmayı güçleştirmektedir. Çünkü kripto paraların fiyat serileri veya getiri serileri hem doğrusal bilgiler hem de doğrusal olmayan bilgiler içermektedir. Dolayısıyla doğrusal regresyon modelleri gibi geleneksel tahmin yöntemleri bu tür piyasalarda işlem gören varlıklara ilişkin tahmin yapmakta başarısız olabilmektedir. Yapay zeka uygulamaları ve makine öğrenmesi gibi yeni teknikler bu noktada çok daha etkin tahmin başarısı sağlayabilmektedir. Özellikle derin öğrenme temelli modeller, karmaşık yapıdaki bilgileri öğrenme kabiliyeti sayesinde kripto piyasalarındaki öngörülemeyen dalgalanmaları daha başarılı tahmin edebilmektedir. Fakat geleneksel yöntemlerin ve yapay zeka tahmin modellerinin

birleştirilerek kullanıldığı tahmin süreçleri bu modellerin tekil olarak kullanılmasından daha başarılı sonuçlar üretmektedir. Hibrit model yaklaşımları, hem ekonometrik yorumlanabilirlik avantajını hem de makine öğrenmesinin yüksek doğruluk potansiyelini harmanlayarak yatırım riskini oldukça düşürmektedir. Bu noktadan hareketle ve Kripto paraların arasındaki ilişkinin ortaya çıkarılması amacıyla Bitcoin, Ethereum, Dogecoin, Ripple ve Solana kripto paraları arasındaki ilişki yapay sinir ağları algoritması ve VAR (Vector Autoregression) modelleri birlikte kullanılarak tahmin edilmiştir. VAR modelleri ilgili varlıklar arasındaki doğrusal ilişkinin ortaya çıkarılması için kullanılırken yapay sinir ağları algoritması doğrusal olmayan ilişkinin modellenmesi için kullanılmıştır. Buna ek olarak, çoklu gecikme yapıları dikkate alınarak model performansı iyileştirilmiştir. Analiz için seçilen kripto varlıklar arasındaki bağlantı ve yayılım etkisi çoklu olarak ele alınmıştır. Elde edilen sonuçların yatırımcılara çeşitlendirme stratejilerinde yol gösterici olacağı ve düzenleyicilere de piyasa istikrarı bakımından değerli girdiler sunacağı öngörülmektedir.

LİTERATÜR TARAMASI

Uzun bir geçmişi olmamasına rağmen kripto para piyasasında bugün binlerce kripto para işlem görmektedir. Yeni bir ödeme sistemi olarak tanıtılan blokzincir teknolojisi bir merkeze bağlı olmadan işlem görmesi, işlemlerin çok hızlı yapılması ve işlem maliyetlerinin düşük olması gibi birçok avantaja sahiptir. Fakat ödeme aracı olarak kullanılmasının ötesinde özellikle 2008 küresel krizinden sonra birçok para biriminin değer kaybetmesi yerel para birimlerinin değer biriktirme aracı olma fonksiyonunu tartışmaya açmıştır. Yeni bir arayış içinde olan yatırımcı için kripto para piyasası bu anlamda önemli bir liman haline gelmiştir. Sonuç olarak bugün dünya nüfusunun neredeyse tamamına ulaşan bir piyasaya dönüşmüştür. Kripto para piyasasındaki bu hızlı ilerleme araştırmacıların da dikkatin çekmiş ve bu alanda birçok çalışmanın yapılmasını sağlamıştır (An vd., 2021; Di Pierro, 2017; Göttfert, 2019; Milutinović, 2018; Gemici ve Polat, 2019; Riedl, R., Gschwentner ve Krueger, 2024; Segendorf, 2014; Siddique vd., 2024; Ur Rehman vd., 2019; Urquhart, 2016; Wattenhofer, 2016; Vranken, 2017). Bu çalışmalarda kripto varlıklar arasındaki yayılım

etkisi analiz edilmiştir (Elsayed ve Sousa, 2024; Liu, Julaiti ve Gou, 2024;; Pacelli, 2025; Zhang vd., 2025). İlgili çalışmaların birçoğu lider kripto paraları arasındaki yayılım etkisini veya bir şokun ne kadarının emildiğini incelemiştir. Söz gelimi Ghaiti (2021) negatif ve pozitif şokları incelemiş ve negatif şokların pozitif şoklardan daha fazla etki yarattığını, bu etkinin en çok Bitcoin ve Dogecoin özelinde ortaya çıktığını ortaya koymuştur. Omane-Adjepong ve Alagidede (2019) Ethereum ve Bitcoin arasındaki volatilité yayılımında Ethereum'dan Bitcoin'e güçlü bir yayılım etkisinin olduğunu buna karşın Bitcoin'nin yayılım etkisinin daha sınırlı ve geçici olduğunu göstermiştir. Bação vd. (2018) yedi farklı kripto para üzerine yaptıkları araştırmada Bitcoin'nin pazarda en çok bilgi yayılımına neden olan kripto para olduğu ve Litecion ile Ripple'ın ise yayılım etkilerinin kısıtlı olduğu sonucuna varmıştır. Beneki vd. (2019) Bitcoin'deki volatilité şoklarının Ethereum'a güçlü geçtiğini fakat tersi ilişkide bu yayılım etkisinin sınırlı olduğunu göstermiştir. Fakat kriz veya pandemi gibi dönemlerde kripto paralar arasındaki bu yayılım etkisi değişiklik gösterebilmektedir (Alica, Özbek ve Gökçe, 2023). Sonuç olarak eldeki bulgular Bitcoin'in lider bir rolü olduğunu ve Ripple, Dogecoin ve Ethereum gibi altcoinlere doğru güçlü bir volatilité yayılım etkisinin olduğunu ve bu etkinin zamanla ortaya çıktığını ifade etmektedir (Ay ve Adıyaman, 2022; Haffelder, 2025; Kubar ve Toprak, 2021; Özekenci, 2023; Sifat, 2019; Soylu vd., 2020; Taleblou ve Mohajeri, 2025).

Kripto paraların etkileşim alanı sadece kendi aralarında değildir. Kripto para piyasasından petrol, menkul kıymetler borsası, GSYH, merkez bankalarının dijital paraları ve emtia gibi varlıklara doğru bir yayılım veya tersi yönde bir yayılım da söz konusudur (Cunha, Melo ve Sebastião 2021; Deniz ve Teker, 2020; Jareño vd., 2021; Kendirli ve Nergiz, 2023; Upadhyay, Raichura, ve Shah, 2018; Zhang ve Mani, 2021). Özellikle kripto para piyasası ile menkul kıymetler borsası arasındaki ilişki ve bu piyasalar arasındaki şok yayılımı birçok çalışmada ele alınmıştır (Iyer and Popescu, 2023). Söz gelimi Wang vd. (2020) Bitcoin fiyatı ile S&P 500 ve NASDAQ getirileri arasındaki ilişkiyi NARDL modeli kullanarak incelemiştir. Pozitif Bitcoin şoklarının hisse senedi piyasalarını anlamlı biçimde etkilemediğini, fakat


negatif Bitcoin şoklarının ise borsa getirilerini düşürdüğünü saptamıştır. Zhou (2024) ağ temelli yöntemlerle kripto paraların finansal piyasalarda yeni bir oyuncu mu yoksa kriz yaratıcı bir unsur mu olduğunu araştırarak, ilişki düzeylerini ve risk yayılımını evrimsel bir bakış açısıyla analiz etmiştir. Sonuç olarak kripto paralardan finansal piyasalara riskin taşındığını göstermiştir. Nas ve Ünal (2023) çalışmasında FED faiz oranları, altın fiyatları ve Bitcoin fiyatlarını ilişkilendirmiştir. Bu çalışmada makine öğrenmesi yöntemleri kullanılmış ve Bitcoinin faiz oranları ve altın fiyatlarından ziyade kendi geçmiş değerlerinden etkilendiğini bulmuştur. Kaya vd. (2020) Covid-19 öncesi ve sonrası döneminde bitcoin fiyat değişimlerini zaman serisi analizi ve makine öğrenmesi yöntemleriyle analiz etmiştir. Sonuçlara göre pandemi öncesi dönem için makine öğrenmesi daha etkin sonuçlar üretirken pandemi sonrası dönemde klasik zaman serisi modelleri daha başarılı tahmin üretmiştir. Dolayısıyla pandemi sonrası dönemde makine öğrenmesi ve yapay zeka tabanlı modellerle kripto para piyasasında yaygın olarak kullanılmıştır (Boozary, Sheykhani ve GhorbanTanhaei, 2025; Chen, 2023; Huang, Sangiorgi ve Urquhart, 2024; Özcan ve Yenikaya, 2025; Ranjan, Kayal ve Saraf, 2023; Terraza, Boru İpek ve Rounaghi, 2024). İlgili çalışmalarda kripto paralara ilişkin başarılı tahminler elde edilmiştir. Benzer biçimde, Iyer ve Popescu (2023), kripto varlıklar ile geleneksel finansal piyasalar arasında gerçekleşen yayılım etkilerini analiz etmiş ve bu ilişkilerin politika yapımcılar açısından göz ardı edilemeyecek boyutlara ulaştığını ortaya koymuştur. Qarni vd. (2019), ABD Bitcoin piyasası ile geleneksel finansal piyasalar arasında volatilité geçişkenliğini incelemiş ve önemli derecede çift yönlü yayılım etkileri tespit etmiştir. Bu sonuçlar, kripto paraların bağımsız birer yatırım aracı olmaktan ziyade finansal sistemle giderek daha fazla bütünleştiğine işaret etmektedir. Cao ve Xie (2022) ise asimetrik dinamik yayılım etkilerini analiz etmiş ve Çin finansal piyasaları ile kripto paralar arasındaki etkileşimi TVP-VAR tabanlı bağlantısallık yöntemiyle incelemiştir. Çalışma, piyasa koşullarına bağlı olarak yayılım etkilerinin yönü ve şiddetinin değişkenlik gösterdiğini ortaya koymuştur. Diğer yandan, kripto para piyasaları ile emtia piyasaları arasındaki ilişkiye odaklanan çalışmalar da literatürde yer almaktadır. Upadhyay, Raichura ve Shah (2018), Deniz ve Teker (2020) ile Jareño vd. (2021), petrol

fiyatları ile kripto para getirileri arasındaki etkileşimi incelemiş ve özellikle kriz dönemlerinde bu iki piyasa arasında anlamlı ilişkiler oluşabileceğini belirtmişlerdir. Bu bulgular, kripto paraların sadece finansal piyasalara değil, aynı zamanda emtia piyasalarına da entegre olduğunu göstermektedir.

YÖNTEM

Yapay sinir ağları algoritmaları (YSA) gerçek bir beyin hücrelerini taklit eden ve karmaşık yapıdaki ilişkileri belli fonksiyonlar kullanarak tahmin etmeye yarayan makine öğrenmesi tabanlı modellerdir (Çam, Ballı ve Sigeze, 2017; Harman, 2022). Yapay sinir ağları algoritması genel olarak bir girdi katmanı bir gizli katman ve bir çıktı katmanından oluşmaktadır (Çam, Sigeze ve Ballı, 2018). Yapay sinir ağları algoritması temelde öğretmenli ve öğretmensiz öğrenme gerçekleştirerek değişkenler arasındaki doğrusal olmayan ilişkileri modellemektedir. Öğretmenli öğrenme için girdi matrisindeki veriler için bir çıktı verisi oluşturulurken, öğretmensiz öğrenme için girdi matrisindeki verilerin çıktı olarak bir karşılığı yoktur ve ağı kendi kendine öğrenmesi istenmektedir. Yapay sinir ağları algoritması güvenlikten, tarıma, enerji verimliliğinden finansa birçok alanda kullanılmaktadır (Alkan ve Durduran, 2024; Castillo-Girones vd., 2025; Çam, 2024; Hamzaçebi ve Kutay, 2004; Kutlu ve Badur, 2009; Wu vd., 2024). Özellikle yüksek işlemcili kişisel bilgisayarların kullanılmasından sonra yapay sinir ağları daha etkin sonuçlar üreterek karmaşık yapıdaki ilişkileri modelleme konusunda önemli çıktılar sağlamıştır. Dahası yapay sinir ağları yeni verileri ağ içinde kullanarak değişkenler arasındaki ilişkilerde meydana gelen değişimlere de uyum sağlayarak uygulamada önemli avantajlar sağlamaktadır. Yapay sinir ağları algoritması karmaşık, rejim değiştiren ve etkileşimli ilişkileri yakalamakta özellikle başarılı tahmin sonuçları sağlamaktadır. Kripto paralar arasındaki ilişkiler genel olarak doğrusal değildir. Dolayısıyla gecikme değerlerinin modele eklenmesi gerekli olduğu durumlarda yapay sinir ağları daha esneklerdir. Başka bir ifade ile yapay sinir ağları algoritması modelleri gecikmesi dağıtılmış modellerde klasik ekonometrik modeller veya zaman serisi modelleri gibi modellenilebilmektedir. Ayrıca yapay sinir ağlarının sağladığı duyarlılık analizi input olarak kullanılan her bir

değişkenin etkisini hesaplamakta oldukça kullanışlıdır. Sonuç olarak finansal değişkenlerin modellenmesinde diğer birçok makine öğrenmesi algoritmasına kıyasla etkin sonuçlar üretme potansiyeline sahiptir. Fakat bütün avantajlarına rağmen yapay sinir ağları algoritması bazı dezavantajlara da sahiptir. En önemli dezavantaj model seçimindeki zorluktur. Bir yapay sinir ağı tahmin edilirken eldeki probleme en uygun ağ yapısını belirlemek oldukça zordur (Çam ve Kılıç, 2018). Bu noktada en etkin ağ yapısını belirleyen katman sayısını, her bir katmandaki düğüm sayısını ve katmanlar arasındaki aktivasyon fonksiyonlarını belirlemenin bir reçetesi yoktur. Her probleme özgü bir ağ yapısı mevcutken bu ağ yapısı genellikle araştırmacının bilgisine dayanmaktadır. Hatta bir probleme uygun olan bir ağ yapısı farklı gözlem sıklığı veya örneklem uzunluğunda bile değişkenlik gösterebilmektedir.



Şekil 1 Yapay Sinir Ağı Yapısı

Şekil 1 bir yapay sinir ağı algoritmasının temel yapısını ifade etmektedir. Burada bir girdi katmanı, bir gizli katman (ara katman) ve bir çıktı katmanı gösterilmiştir. Her bir katman arasında düğümleri birbirine bağlayan ağırlıklar mevcuttur. Yapay sinir ağının öğrenme süreci girdi katmanı ile çıktı katmanı arasındaki ilişkiyi en iyi açıklayan ağırlıkların hesaplanması sürecidir. Düğümler arasındaki bilgi akışı bu ağırlıklar sayesinde taşınmaktadır ve optimal düzeye gelmiş ağırlıklar hesaplandıktan sonra ağı eğitimi tamamlanmaktadır. Yapay sinir ağları yapısı

gereği doğrusal olmayan ilişkileri modellemekte oldukça başarılıdır. Bu noktadan hareketle bu çalışmada yapay sinir ağları yüksek volatilitelere sahip ve oldukça karmaşık yapıdaki kripto varlıkların getirini tahmin etmek için kullanılmıştır. Uygulama aşamasında Ocak 2020 ile Ocak 2025 tarihlerini kapsayan günlük getiriler kullanılmıştır. Bitcoin, Ripple, Ethereum, Dogecoin ve Solana kripto varlıklarına ait veriler yapay sinir ağlarının girdi ve çıktı değişkenlerini oluşturmuştur. Analiz dönemi içerisinde piyasalardaki oynaklığı önemli ölçüde etkileyen Covid 19 pandemisi vuku bulmuştur. Pandemi öncesi ve sonrası dönemde finansal değişkenler arasındaki ilişkinin farklılık göstermesi olasıdır. Pandemi öncesi dönemde finansal serilerde daha karmaşık ilişkin olası iken, pandemi sonrası dönemdeki pozitif trend değişkenler arasındaki ilişkinin daha deterministik olmasına yol açmıştır. Dolayısıyla, pandemi öncesi dönemde klasik ekonometrik yöntemlerden ziyade makine öğrenmesi temelli yöntemler daha başarılı olmuştur (Kaya vd. 2020). Başka bir deyişle, serilerin içerdiği benzer trendeler makine öğrenmesi yöntemlerinin tahmin gücünün artmasını sağlamaktadır. Model tahmini yapılırken her defasında bir kripto varlığın getiri serisi çıktı verisi olarak kullanılmıştır. Buna karşın Bitcoin ve diğer alt coin getiri serileri ise girdi verisi olarak kullanılmıştır. Tahmin edilen yapay sinir ağı algoritmalarının matematiksel yapıları aşağıda gösterilmiştir.

$$\text{Dogecoin} = f(\text{Bitcoin}, \text{Ethereum}, \text{Ripple}, \text{Solana}) \quad (1)$$

$$\text{Ethereum} = f(\text{Bitcoin}, \text{Dogecoin}, \text{Ripple}, \text{Solana}) \quad (2)$$

$$\text{Ripple} = f(\text{Bitcoin}, \text{Ethereum}, \text{Dogecoin}, \text{Solana}) \quad (3)$$

$$\text{Solana} = f(\text{Bitcoin}, \text{Ethereum}, \text{Ripple}, \text{Dogecoin}) \quad (4)$$

Yukarıdaki ilişkide bir kripto varlığı Bitcoin ve diğer kripto varlığının getirileriyle ilişkilendirilmiştir. Fakat menkul kıymetler borsasında olduğu gibi kripto varlık piyasasında da varlıklar sadece mevcut günün bilgilerini içermemektedir. Bir varlığın fiyatına veya getirisine gelen bir şokun etkisi genellikle bir veya birkaç gün sonra ortaya çıkmaktadır. Dolayısıyla modele açıklayıcı değişkenlerin gecikmeli değerleri de eklenmelidir. En uygun gecikme sayısı bu anlamda VAR yöntemi ile belirlenmiştir. VAR modelinin işaret ettiği gecikme uzunluğu kadar değişken modele açıklayıcı değişken olarak dahil edilirken etki tepki fonksiyonları ve yapay sinir ağları algoritması modelleri bu bilgiler ışığında elde edilmiştir.

ARAŞTIRMA BULGULARI

Tablo 1 analizde kullanılan Bitcoin, Dogecoin, Ethereum, Solana ve XPR kripto paralarına ait özet istatistikleri göstermektedir. Özet istatistikler değişkenlerin yüzde değerlerinden elde edilmiştir. Buna göre Bitcoin analiz döneminde günlük ortalama %0,196 getiri sağlarken, Dogecoin aynı dönemde %0,638 getiri sağlamıştır. Ethereum, Solana ve Ripple ise sırasıyla %0,237, %0,532 ve %0,322 ortalama günlük getiri sağlamıştır. Kripto para piyasası doğası gereği yüksek oynaklık içermektedir. Dolayısıyla ortalama getiriler kadar bir kripto paranın volatilitesi de önemlidir. Standart sapma değerleri bu anlamda iyi bir volatilité göstergesidir. Analize dahil edilen kripto paralar içinde en yüksek oynaklığa sahip varlık Dogecoin'dir. Solana ve Ripple varlıkları sırasıyla 6,872 ve 5,873 standart sapma değerleriyle Dogecoin'i takip etmektedir.

Tablo 1 Özet İstatistikler


	BITCOIN	DOGECOIN	ETHEREUM	SOLANA	RIPPLE
Ortalama	0.196	0.638	0.237	0.532	0.322
Medyan	0.062	0.016	0.170	0.038	0.100
Maksimum	19.564	387.367	26.464	64.858	73.148
Minimum	-15.684	-39.488	-27.860	-42.354	-41.851
Std. Sapma	3.195	11.801	4.225	6.872	5.873
Çarpıklık	0.124	21.935	0.188	0.933	2.554
Basıklık	6.403	700.130	7.940	12.117	31.237
Jarque-Bera	806.904	33808452	1700.445	6000.549	57054.5
Olasılık	0.0000	0.0000	0.0000	0.0000	0.0000

Geleneksel ekonometrik analizlerde tahmini yapılan değişkenlerin normal dağılması oldukça önemlidir. Fakat yüksek volatiliteye sahip likit piyasalara ait verilerde genellikle bu varsayım karşılanamaz. Dolayısıyla ampirik analiz içeren çalışmalarda bazı sorunlar meydana gelmektedir. Çünkü çoğu ekonometrik model gözlemlerin normal dağıldığını varsaymaktadır ve bu varsayım yerine gelmediğinde tahmin modelinin gücü düşmektedir. Tablo 1'deki Jarque-Bera normallik testine göre analizde kullanılan değişkenlerin tamamı normal dağılmamaktadır. Verilerin normallik varsayımına ek olarak değişkenlerin durağan olması uygulanacak ekonometrik modelin seçiminde kritik bir öneme sahiptir. Değişkenlerin durağan olmadan analize dahil edilmesi sahte regresyon sorununa yol açarak güvenilir olmayan tahmin sonuçlarına neden olabilmektedir.

Tablo 2 ADF Birim Kök Test Sonuçları


Değişken	Trend ve Sabit	Sabit	Trendsiz & Sabitsiz
Bitcoin	-42.080	-42.084	-41.934
Dogecoin	-21.879	-21.812	-21.696
RIPPLE	-41.091	-41.103	-40.991
Ethereum	-43.103	-42.997	-42.868
Solana	-42.658	-42.557	-42.298
1%	-3.9636	-3.4341	-2.5664
5%	-3.4125	-2.8631	-1.9410
10%	-3.1282	-2.5676	-1.6166

Tablo 2 değişkenlere ait ADF birim kök testi sonuçlarını göstermektedir. Sonuçlara göre Bitcoin, Dogecoin, Ripple, Ethereum ve Solana kripto paralarına ait günlük getiri serileri hem trendli&sabitli modelde hem sabitli modelde hem de trendsiz&sabitsiz modelde düzeyde durağandır. Değişkenler mevcut haliyle ekonometrik bir analizde kullanılabilir. Analizdeki ilk adım VAR analizi ile değişkenler arasındaki gecikmeli ilişkinin tespit edilmesi yer almaktadır.



Şekil 2 Etki Tepki Fonksiyonları

Şekil 2 Solana ve Ethereum kripto paralarının diğer kripto paralara verdiği tepkiler yer almaktadır. Buna göre Solana'nın Ripple tepkisi istatistiksel olarak anlamlı değildir. Aynı şekilde Dogecoin, Bitcoin ve Ethereum'un da Solana üzerinde anlamlı bir etkisi görünmemektedir. Tüm bu değişkenler için sıfırı içermektedir. Şeklin sağ tarafında Ethereum değişkeninin diğer kripto paralara verdiği tepkiler yer almaktadır. Solana'ya gelen bir şok Ethereum üzerinde pozitif ve artarak devam eden bir etkiye sahiptir. Buna göre Ethereum değişkeninin Solana değişkenine tepkisi ilk üç gün artmakta, dördüncü gün biraz düşüş eğilimi göstermekte ve beşinci günden sonra bu etki sabit kalmaktadır. Ethereum'un diğer kripto paralarına verdiği tepki istatistiksel olarak anlamlı değildir. Tüm bu tepkiler sıfır sınırını içermektedir.



Şekil 3 Etki Tepki Fonksiyonları

Şekil 3 Ripple ve Doceoin'nin diğer kripto paralara verdiği tepkiler yer almaktadır. Buna göre Ripple'nin Dogecoin'e verdiği kümülatif tepki iki ile üçüncü günler artarken diğer günlerde stabil bir hale geçmektedir. Ripple'nin Bitcoin

ve Solana'ya tepkisi istatistiksel olarak anlamlı değildir. Ethereum'un Ripple üzerindeki etkisi ise veya başka bir ifade ile RİPPLE'nin Ethereuma tepkisi üçüncü günden sonra istatistiksel olarak anlamlı hale gelmektedir. Bu tepki pozitif ve kararlıdır. Son olarak Dogecoin getirilerinin diğer kripto para getirilerindeki şoklara verdiği tepkiler şekil 2'nin sağ tarafında gösterilmektedir. Burada Dogecoin'nin Bitcoin'e verdiği tepki göze çarpmaktadır. Dogecoin Bitcoin'deki bir şoka ilk üç gün negatif ve istatistiksel olarak anlamlı bir tepki verirken devam eden günlerde etki sönümlenerek istatistiksel olarak anlamsız hale gelmektedir. Ethereum'daki bir şoka ise Dogecoin'nin verdiği tepki ilk günden itibaren pozitif ve istatistiksel olarak anlamlı hesaplanmıştır. Tepki beşinci günden sonra sönümlenmesine rağmen analiz dönemi içindeki on gün boyunca devam etmektedir. Dogecoin'nin Solana ve Ripple'ta meydana gelen şoklara tepkisi de benzer şekildedir. Buna göre analiz edilen on gün boyunca Dogecoin'nin tepkisi pozitif ve istatistiksel olarak anlamlı devam etmektedir.

Etki tepki fonksiyonları geleneksel ekonometrik modellerden VAR analizi sonucunda elde edilmektedir. VAR analizi değişkenler arasındaki doğrusal ilişkiyi yakalamakta başarıyla doğru olmayan ilişkilerin tahmininde etkisiz kalabilmektedir. Dolayısıyla doğrusal olmayan ilişkilerin tahmini noktasında makine öğrenmesi yöntemlerinden birini kullanmak daha etkin sonuçlar üretmek adına gerekli olabilmektedir. Burada VAR modeli ve etki tepki fonksiyonlarına ek olarak yapay sinir ağları algoritması en çok işlem gören ilk beş kripto paranın arasındaki doğrusal olmayan ilişkileri tahmin etmek için kullanılmıştır.

Tablo 3 YSA Algoritması Model Özetleri

Ripple				Dogecoin			
		N	Oran			N	Oran
Örneklem	Eğitim	1178	%71.0	Örneklem	Eğitim	1168	%70.4
	Test	481	%29.0		Test	491	%29.6
Uygunluk		1659	%100.0	Uygunluk		1659	%100.0
Dışlanan		9		Dışlanan		9	
Toplam		1668		Toplam		1668	
Ethereum				Solana			
		N	Oran			N	Oran
Örneklem	Eğitim	1191	%71.8	Örneklem	Eğitim	1152	%69.4
	Test	468	%28.2		Test	507	%30.6
Uygunluk		1659	%100.0	Uygunluk		1659	%100.0
Dışlanan		9		Dışlanan		9	
Toplam		1668		Toplam		1668	

Tablo 4 YSA Model Tahmin Özeti

		Ripple	Dogecoin	Ethereum	Solana
Eğitim	HKT	61.121	47.565	29.915	20.529
	Nispi Hata	.104	.082	.050	.036
	Eğitim süresi	0:00:00.23	0:00:00.11	0:00:00.14	0:00:00.17
Test	HKT	20.355	26.217	10.273	10.510
	Nispi Hata	.106	.098	.044	.044

Tablo 3 tahmin edilen yapay sinir ağıları algoritması modellerine ait özetleri içermektedir. Tahmin sürecinde kullanılan modeller en iyi tahmin başarısına sahip on model içinden seçilmiştir. Her bir kripto para getiri tahmini için örneklem yaklaşık %70'i eğitim verisi olarak kullanılırken yaklaşık %30 gözlem test için kullanılmıştır. Model tahmini yapılırken test verisi %20 ile %40 arasında değişecek şekilde değiştirilmiştir. Fakat bu değişiklikler model tahmini üzerinde anlamlı bir etki yapmadığı için geleneksel eğitim test oranı kullanılmıştır.

Tablo 4 kripto paralar arasındaki ilişkiyi en iyi tahmin eden yapay sinir ağıları algoritması modellerinin hata kareler toplamı, nispi hata ve ağ eğitim süresini göstermektedir. Test verisi özelinde Ethereum ve Solana tahmin modelleri veriye en iyi uyum sağlayan yapay sinir ağıları modelleridir. Dogecoin ise nispi olarak en kötü performansı gösteren modeldir. Bu sonuç beklentilerle uyumludur. Tablo 1'deki

özet istatistiklerde Dogecoin en yüksek volatiliteye sahip alt coin olarak hesaplanmıştır. Dolayısıyla bu değışkene ait getiri serisinin nispeten daha düşük tahmin performansına sahip olması doğaldır. Yapay sinir ağıları algoritması tahmin edilirken açıklayıcı değışken olarak kullanılan her bir değışkenin beş günlük gecikmesi alınmıştır. Finansal seriler genel olarak sadece mevcut dönemden değil önceki dönemlerden de etkilenmektedir. Sonuç olarak yüksek oynaklığa sahip ve yüksek belirsizlik içeren bu tür değışkenlerin tahmin sürecinde gecikmeli değışkenlerin etkisi göz ardı edilmemelidir.

Tablo 5 dört alt coin için tahmin edilmiş yapay sinir ağıları algoritmasının duyarlılık analizi sonuçlarını içermektedir. Bir alt coin için model tahmin edilirken diğer alt coinler ve Bitcoin'nin beş gecikmesi modele girdi verisi olarak girilmiştir. Çıktı verisi ise ilgili kripto paranın getiri serisidir. Öğretmenli öğrenimin yapıldığı yapay sinir ağı

modellerinde en iyi tahmin sonucunu veren ağ toplamda on kez tahmin edilmiş modeller arasından seçilmiştir. Ripple kripto para getirileri için tahmin edilen model sonuçlarına göre Ripple getirisindeki bir şokun %12,2'si Dogecoin'nin mevcut günlük getirisi tarafından açıklanmaktadır. Modelde toplam dört kripto para açıklayıcı değişken olarak kullanıldığı için her bir alt coinin getirilerine gelen şokun

sadece bu açıklayıcı değişkenler tarafından etkilendiği varsayılmaktadır. Dolayısıyla mevcut bir birimlik şokun %12,2'lik açıklanma oranı ile en çok Dogecoin tarafından etkilendiği söylenebilir. Şekil 2'deki etki tepki fonksiyonları da bu bulguyu desteklemektedir. VAR modeli tabanlı elde edilen etki tepki fonksiyonuna göre Ripple getirileri en çok Dogecoin getirilerine tepki vermektedir.

Tablo 5 YSA Algoritması Duyarlılık Analizi

Değişken	Ripple		Dogecoin		Ethereum		Solana	
	Önem (%)	Normalize Önem (%)	Önem (%)	Normalize Önem (%)	Önem (%)	Normalize Önem (%)	Önem (%)	Normalize Önem (%)
Bitcoin	0.021	0.173	0.035	0.236	0.049	0.648	0.033	0.289
Bitcoin1	0.038	0.312	0.037	0.251	0.041	0.544	0.037	0.327
Bitcoin2	0.021	0.171	0.026	0.175	0.027	0.355	0.028	0.245
Bitcoin3	0.040	0.324	0.051	0.339	0.046	0.599	0.033	0.291
Bitcoin4	0.023	0.191	0.027	0.178	0.032	0.422	0.027	0.234
Bitcoin5	0.050	0.407	0.019	0.127	0.076	1.000	0.037	0.326
Dogecoin	0.122	1.000	-	-	0.055	0.716	0.072	0.627
Dogecoin1	0.014	0.117	-	-	0.045	0.585	0.033	0.288
Dogecoin2	0.029	0.233	-	-	0.028	0.368	0.045	0.395
Dogecoin3	0.084	0.686	-	-	0.030	0.400	0.049	0.427
Dogecoin4	0.032	0.263	-	-	0.027	0.355	0.038	0.335
Dogecoin5	0.074	0.603			0.072	0.951	0.043	0.373
Ethereum	0.040	0.327	0.035	0.234	-	-	0.115	1.000
Ethereum1	0.039	0.323	0.028	0.190	-	-	0.038	0.328
Ethereum2	0.044	0.358	0.028	0.190	-	-	0.023	0.200
Ethereum3	0.055	0.454	0.038	0.254	-	-	0.036	0.311
Ethereum4	0.032	0.263	0.058	0.389	-	-	0.049	0.431
Ethereum5	0.037	0.306	0.025	0.170			0.068	0.592
Solana	0.029	0.234	0.025	0.170	0.017	0.229	-	-
Solana1	0.017	0.140	0.029	0.196	0.045	0.585	-	-
Solana2	0.054	0.443	0.037	0.245	0.071	0.931	-	-
Solana3	0.039	0.316	0.017	0.112	0.035	0.466	-	-
Solana4	0.028	0.228	0.027	0.181	0.042	0.550	-	-
Solana5	0.038	0.308	0.025	0.170	0.040	0.521		
Ripple	-	-	0.041	0.276	0.038	0.504	0.035	0.305
Ripple1	-	-	0.149	1.000	0.046	0.601	0.036	0.318
Ripple2	-	-	0.036	0.242	0.033	0.437	0.030	0.262
Ripple3	-	-	0.047	0.315	0.027	0.357	0.028	0.242
Ripple4	-	-	0.064	0.429	0.049	0.650	0.034	0.300
Ripple5			0.093	0.623	0.027	0.353	0.031	0.271


Benzer şekilde Ripple getiri serisine gelen bir şokun sadece %1,4'ü Dogecoin'nin bir önceki gün getiri serisi tarafından belirlenmektedir. İlk günden beşinci günün sonuna kadar ise Dogecoin'nin Ripple üzerindeki toplam etkisi %35 civarındadır. RİPPLE getirilerindeki bir şokun Bitcoin, Dogecoin, Ethereum ve Solana tarafından belirlendiği varsayımı altında bu etkinin üçte birinden fazlası Dogecoin'e ait olduğu söylenebilir. Dogecoin getirilerinin tahmin edildiği yapay sinir ağı modeline göre bu serideki bir şokun %14,9'u Ripple'nin bir gün önceki getirisi tarafından açıklanmaktadır. Bu oran Ripple ile Dogecoin arasında güçlü bir etkileşimin olduğunu göstermektedir. Ripple getirilerdeki bir şokun en az etkilendiği değişken ise %0,17 ile Solana'nın bir önceki gün getirisidir. Ek olarak, Ripple'nin Dogecoin üzerindeki toplam etkisi %43 civarındadır. Bir diğer kripto para olan Ethereum için tahmin edilen yapay sinir ağı modeli sonuçlarına göre bu değişkene gelen bir şokun %7,6'sı Bitcoin'nin beş gün önceki getirisinden kaynaklanmaktadır. Bu Ethereum değişkenine gelen bir şokun en yüksek olduğu orandır. Son olarak Solana getirilerine gelen bir şokun %11,5'i Ethereum tarafından açıklanmaktadır. Bu anlamda en az etki Ethereum'un iki gün önceki getirisinden gelmektedir.

Tablo 6 YSA Algoritması Duyarlılık Analizi Toplam Etkiler

	Ripple	Dogecoin	Ethereum	Solana
Bitcoin	0.193	0.195	0.272	0.196
Ripple		0.431	0.221	0.195
Dogecoin	0.355		0.257	0.280
Ethereum	0.248	0.213		0.328
Solana	0.204	0.161	0.25	
Toplam	1.000	1.000	1.000	1.000

Tablo 6 her bir kripto paranın üzerindeki diğer değişkenlerin toplam etkisini göstermektedir. VAR modeli gecikme uzunluğuna göre seçilen beş günlük gecikme sayıları her bir alt coinin tahmininde kullanılmıştır. Dolayısıyla Tablo 6'daki değerler ilgili değişkenin beş günlük toplam etkisini göstermektedir. Buna göre Ripple'daki bir şokun %19,3 Bitcoin'den gelmektedir. Bu etki t, (t-1), (t-2), (t-3), (t-4) ve (t-5) gündeki etkilerin toplamıdır. Ripple'deki bir şokun toplam %35,5'i bu anlamda Dogecoin'den, %24,8'i Ethereum'dan ve %20

,4 ise Solana'dan gelmektedir. Tablodaki değerler normalize edildiği için tüm etkilerin toplamı %100 olarak hesaplanmıştır. Benzer şekilde Dogecoin'nin çıktı değişkeni olduğu modellerde en yüksek etkiye sahip kripto para Ripple olarak hesaplanmıştır. Buna göre Dogecoin getirilerinde meydana gelen bir birimlik şokun %43,1'i Ripple tarafından açıklanmaktadır. RİPPLE'i %21,3 ile Ethereum takip ederken Bitcoin ve Solana %19,5 ve %16,1 ile Bitcoin'i takip etmektedir. Ethereum'da durum daha karardır. Ethereum'a gelen bir şokun diğer kripto paralardan etkilenme oranları nispeten dengeli dağılmıştır. Buna göre Bitcoin %27,2 ile en çok etkiye sahip kripto olsa da genel olarak etkiler dörtte bir oranında dağılmıştır. Son olarak Solana kripto parasında gelen şokun dağılımı incelenmiştir. Burada en yüksek pay %32,8 ile Ethereum'a aittir. Bitcoin ve Ripple'in etkileri eşitken Dogecoin %28 etkiye sahiptir.



Şekil 4 Duyarlılık Analizi Ağ Grafikleri

Şekil 4 duyarlılık analizinden elde edilen ağırlıkları detaylı olarak sunmaktadır. Şekil 4'ün sol üst köşesindeki grafik Dogecoin'ne aittir. Grafik girdi verisi olarak kullanılan her bir değişkenin Dogecoin'e gelen bir şokta ne kadar pay sahibi olduğunu göstermektedir. Ripple'ın bir önceki gün değeri (t-1) mevcut dönem Dogecoin getirisi (t) üzerinde en çok etkiye sahip gözlemdir. Ripple ve Dogecoin arasında (sağ üst köşe) eşzamanlı bir etkileşim söz konusudur. (t) gününde Dogecoin'e gelen bir şokun Ripple'a aktarımı aynı gün içinde gerçekleşmektedir. Benzer bir etki Solana ve Ethereum arasında da hesaplanmıştır. Ethereum'un getirisine gelen bir şokun Solana'ya geçmesi aynı gün

içinde olmaktadır. Son olarak Ethereum günlük getirilerinin çıktı değişkeni olarak tahmin edildiği modelden elde edilen duyarlılık analizi sonuçları (t-5) gününde Bitcoin ve Dogecoin’ de meydana gelen bir şokun beş gün sonra, yani t gününde Ethereum’a geçtiğini göstermektedir.

Yapılan analizler Bitcoin → Ethereum → Solana ve Ripple ↔ Dogecoin gibi iki ilişki grubu olduğunu göstermektedir. Bitcoin kripto paraların ana teknolojisini oluşturmaktadır ve birçok alt kripto para üzerinde önemli bir etkiye sahiptir. Fakat Ripple ve Dogecoin gibi yüksek piyasa payına sahip paralar üzerinde görece daha az etkiye sahiptir. Sonuçlar bir bütün olarak değerlendirildiğinde Bitcoin’den Ethereum’a doğru, Ethereum’dan da Solana’ya doğru bir şok transferi olduğu anlaşılmaktadır. Bitcoin’de oluşan pozitif ya da negatif şoklar ilk olarak Ethereum’a, ardından da Solana’ya taşınmaktadır. Bu sıra, hem likidite derinliği hem de teknolojik göç (geliştiricilerin ve kullanıcıların yeni zincirlere geçişi) ile açıklaması mümkündür. Ethereum’un “proof-of-stake” mutabakat algoritmasına geçişi likiditeyi kendine çekerken, Solana’nın yüksek işlem kapasitesi bu likiditenin ikinci durağı olmaktadır. Böylece Bitcoin kaynaklı bilgi önce Ethereum fiyatlarına yasırken, yaklaşık beş gün içinde Solana’da tam olarak fiyatlanmaktadır. Diğer taraftan, Ripple ve Dogecoin arasındaki şok transferi ise karşılıklıdır. Her iki varlık da perakende odaklı, sosyal-medya temelli haber akışına duyarlıdır. Twitter/X, Discord ve Telegram’daki trendler genellikle aynı gün Dogecoin’i harekete geçirirken, bir gün sonra bu etki XRP’a taşınmaktadır. Ardından döngü tersine dönerek şoklar Dogecoin’e doğru yaklaşık beş gün boyunca zayıflayarak sürmektedir. Bu yapı, ortak yatırımcı tabanının “meme coin” psikolojisi ile birleşip tek bir fiyat keşif alanı olarak bu iki kripto paranın değerlendirildiğini göstermektedir. Bununla birlikte, analiz dönemi içerisinde gerçekleşen, küresel ölçekte hem reel hem finansal piyasaları derinden etkileyen Covid 19 pandemisi, kripto para piyasasını da etkilemiştir. Belirsizlik ve korkunun yaygın olduğu dönemde, yatırımcı karamsarlığını yatırımcı davranışlarının da önemli ölçüde değişmesine yol açmıştır. Pandemi süreci, genel olarak tüm piyasalardaki düşüşe karşın kripto para piyasalarında öngörülme-yen bir yükselişi beraberinde getirmiştir. Özellikle geleneksel piyasalardan kripto piyasalara doğru bir geçiş olduğu ve bu piyasalar

arasında güçlü bir şok yayılım etkisinin bulunduğu ampirik çalışmalarla da tespit edilmiştir(Mnif vd. 2022; Soltani vd.,2025).

SONUÇ

Kripto varlıklar piyasası oldukça karmaşık bir yapıya sahip yüksek oynaklık içeren bir piyasadır. Merkeziyetsiz finansal varlık varsayımı ile ortaya atılan bu teknolojiler tıpkı menkul kıymetler borsası gibi birçok faktörden aynı anda etkilenmektedir. Bu çalışma dış faktörleri göz ardı ederek piyasa içindeki bir şokun diğer kripto varlıklar üzerindeki kısa vadeli etkilerini incelemektedir. Temel kripto para olarak işlem gören Bitcoin’e ek olarak piyasada en çok paya sahip Dogecoin, Ripple, Solana ve Ethereum analize dahil edilerek söz konusu piyasa içindeki şokların etkileri hesaplanmıştır. Çalışmada geleneksel ekonometrik modellerden VAR analizi ve etki-tepki fonksiyonlarına ek olarak yapay sinir ağları algoritması kullanılmıştır. Sonuçlar ele alınan beş kripto varlığın iki blok şeklinde şokları ilettiğini göstermektedir. Buna göre Bitcoin-Ethereum-Solana üçlüsü ile Dogecoin-Ripple ikilisi arasında iki farklı “bağlantı ağı” bulunmaktadır. Bu bağlantı ağları içindeki şoklar yaklaşık olarak beş gün boyunca devam etmektedir. Gecikmeli etkiler, beş gün boyunca şokların sindirildiğini ve haber fiyatlamasının anlık değil, katmanlı olarak gerçekleştiğini göstermektedir. Katmanlı etkiler en çok Ethereum kripto parasında ortaya çıkmaktadır. Bitcoin’e gelen bir şok yaklaşık olarak beş gün sonra Ethereum’a geçerken, Ethereum’dan Solana’ya geçiş aynı gün içinde gerçekleşmektedir. Dogecoin ve Ripple arasındaki şok yayılımı ise çok daha kısa sürede gerçekleşmektedir ve bu iki varlık arasındaki şoklar çift yönlüdür. Dogecoin veya Ripple’a gelen bir şok çok hızlı bir şekilde diğer varlığa sirayet etmektedir. Dogecoin ve Ripple’ın sosyal medyadaki etkileşimlere duyarlılığı çok yüksek olduğu için muhtemelen birine gelen bir şok sosyal medyadaki hızlı bilgi akışı sayesinde vakit kaybetmeden diğerine taşınmaktadır.

Sonuçlar kripto varlıklara yatırım yapan yatırımcılara önemli bilgiler sağlamaktadır. Klasik portföy teorisindeki eş zamanlı çeşitlendirme ile yatırım riskinin minimuma indirilmesi varsayımı kripto para piyasası için büyük oranda geçerliliğini yitirmektedir. Bu piyasalarda yatırım

kararı alan yatırımcılar çeşitlendirmeyi gecikmeli olarak gerçekleştirmesi sayesinde riskten büyük oranda kaçınması mümkündür. Bu kapsamda portföy yöneticileri portföy içindeki varlık dağılımı ve değişimini yayılım etkisinin zaman içerisinde meydana gelmesine dikkat ederek gerçekleştirmelidir. Sonuçlar özellikle Dogecoin ve Ripple arasındaki geçişkenliğin hızlı olması nedeniyle bu varlıklara gelen bir şokun portföy yöneticisi tarafından hemen dikkate alınması gerektiğini göstermektedir. Fakat Ethereum ve Bitcoion varlıklarındaki yayılım etkisi beş günde ortaya çıktığı için bu varlıklara karşı alınacak pozisyon değişikliklerinin kademeli olarak gerçekleştirilmelidir. Bu sayede yatırımcılar kripto varlıklar arasındaki risk geçişinden en az oranda etkilenmiş olacaktır. Sonuç olarak, kripto varlıklar arasındaki şokların yönünü ve zamanını takip ederek piyasa ortalama getirisinin üzerinde bir getiri elde edebilir ve yatırım getirisini maksimum yapabilirler.

KAYNAKLAR

- Akçalı, B. Y. ve Şişmanoğlu, E. (2019). Kripto para birimleri arasındaki ilişkinin Toda–Yamamoto nedensellik testi ile analizi. *Ekev Akademi Dergisi*, (78), 99–122.
- Alica, S., Özbek, Ö. ve Gökçe, A. (2023). Kripto para birimleri arasındaki dinamik ilişkiler. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 25(1), 325–342.
- Alkan, T. ve Durduran, S. S. (2024). Meyve bahçelerinin çoklu regresyon analizi ve yapay sinir ağları ile değerlemesi. *Türkiye Arazi Yönetimi Dergisi*, 6(1), 1–8.
- An, Y. J., Choi, P. M. S. ve Huang, S. H. (2021). Blockchain, cryptocurrency, and artificial intelligence in finance. In *Fintech with Artificial Intelligence, Big Data, and Blockchain* (s. 1–34). Springer Singapore.
- Ay, M. ve Adıyaman, G. (2022). Bitcoin ve altcoinler arasındaki ilişkinin incelenmesi. *Selçuk Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, (47), 31–46.
- Baçaõ, P., Duarte, A. P., Sebastião, H. ve Redzepagic, S. (2018). Information transmission between cryptocurrencies: Does Bitcoin rule the cryptocurrency world? *Scientific Annals of Economics and Business*, 65(2), 97–117.
- Beneki, C., Koulis, A., Kyriazis, N. A. ve Papadamou, S. (2019). Investigating volatility transmission and hedging properties between Bitcoin and Ethereum. *Research in International Business and Finance*, 48, 219–227.
- Boozary, P., Sheykhani, S., ve GhorbanTanhaei, H. (2025). Forecasting the Bitcoin price using the various Machine Learning: A systematic review in data-driven marketing. *Systems and Soft Computing*, 200209.
- Cao, G. ve Xie, W. (2022). Asymmetric dynamic spillover effect between cryptocurrency and China's financial market: Evidence from TVP-VAR based connectedness approach. *Finance Research Letters*, 49, 103070.
- Castillo-Girones, S., Munera, S., Martínez-Sober, M., Blasco, J., Cubero, S. ve Gómez-Sanchis, J. (2025). Artificial neural networks in agriculture, the core of artificial intelligence: What, when, and why. *Computers and Electronics in Agriculture*, 230, 109938.
- Chen, J. (2023). Analysis of bitcoin price prediction using machine learning. *Journal of risk and financial management*, 16(1), 51.
- Cunha, P. R., Melo, P. ve Sebastião, H. (2021). From Bitcoin to central bank digital currencies: Making sense of the digital money revolution. *Future Internet*, 13(7), 165.
- CoinMarketCap. (2024). Cryptocurrencies, Historical Snapshot - 30 June 2024. Erişim adresi: https://coinmarketcap.com/historical/20240630/?utm_source=chatgpt.com
- Çam, S. (2024). Does the exchange rate have a pass-through effect on domestic food prices in Türkiye? An empirical study using a combined ANN algorithm and VAR method. *Gaziantep Üniversitesi Sosyal Bilimler Dergisi*, 23(3), 1046-1059.
- Çam, S. ve Kılıç, S. B. (2018). Altın fiyatı günlük getirilerinin yapay sinir ağları algoritması ve Markov zincirleri modelleri ile tahmini. *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, 681–694.
- Çam, S., Ballı, E. ve Sigeze, Ç. (2017). Petrol fiyatlarındaki oynaklığın ARCH/GARCH modelleri ve yapay sinir ağları algoritması ile tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 13(13), 588–597.
- Çam, S., Sigeze, Ç. ve Ballı, E. (2018). Türkiye'nin enerji verimliliğinin yapay sinir ağı ve ARDL yaklaşımı ile analizi. *Ege Academic Review*, 18(4), 661–670.
- Dai, W. (1998). *b-money*. <http://www.weidai.com/bmoney.txt>
- Deniz, A. ve Teker, D. (2020). Determinants of cryptocurrency market: An analysis for Bitcoin, Ethereum and Ripple. *International Journal of Business and Social Science*, 11(11), 36–45.
- Di Pierro, M. (2017). What is the blockchain? *Computing in Science & Engineering*, 19(5), 92–95.
- Duarte, F. (2025). How many cryptocurrencies are there in 2025? Erişim adresi: <https://explodingtopics.com/blog/number-of-cryptocurrencies> (Erişim tarihi: 03/04/2025).
- Elsayed, A. H. ve Sousa, R. M. (2024). International monetary policy and cryptocurrency markets: Dynamic and spillover effects. *The European Journal of Finance*, 30(16), 1855–1875.
- Gemici, E. ve Polat, M. (2019). Relationship between price and volume in the Bitcoin market. *The Journal of Risk Finance*, 20(5), 435–444.
- Ghaiti, K. (2021). *The volatility of Bitcoin, Bitcoin Cash, Litecoin, Dogecoin and Ethereum* (Doktora tezi, University of Ottawa).
- Göttfert, J. (2019). Cointegration among cryptocurrencies: A cointegration analysis of Bitcoin, Bitcoin Cash, EOS, Ethereum, Litecoin and Ripple.
- Haffelder, W. H. (2025). *A correlational-predictive study examining Bitcoin close price and volume and the close price of Dogecoin* (Doktora tezi, Grand Canyon University).

- Hambiralovic, M. ve Karlsson, R. (2018). Blockchain accounting in a triple-entry system.
- Hamzaçebi, C. ve Kutay, F. (2004). Yapay sinir ağları ile Türkiye elektrik enerjisi tüketiminin 2010 yılına kadar tahmini. *Gazi Üniversitesi Mühendislik Mimarlık Fakültesi Dergisi*, 19(3).
- Harman, G. (2022). Altın/Dolar paritesinin farklı yapay sinir ağları öğrenme algoritmaları kullanarak bir sonraki kur tahmini. *Veri Bilimi*, 5(1), 1–12.
- Huang, Z. C., Sangiorgi, I., ve Urquhart, A. (2024). Forecasting Bitcoin volatility using machine learning techniques. *Journal of International Financial Markets, Institutions and Money*, 97, 102064.
- Iyer, R. ve Popescu, A. (2023). New evidence on spillovers between crypto assets and financial markets. *International Monetary Fund*.
- Jareño, F., González, M. D. L. O., López, R. ve Ramos, A. R. (2021). Cryptocurrencies and oil price shocks: A NARDL analysis in the COVID-19 pandemic. *Resources Policy*, 74, 102281.
- Kaya, U., Akba, F., Medeni, İ., ve Medeni, T. (2020). Covid-19 öncesi ve sonrasındaki Bitcoin fiyat değişimlerinin Makine Öğrenmesi, zaman serileri analizi ve derin öğrenme yöntemleriyle değerlendirilmesi. *Bilişim Teknolojileri Dergisi*, 13(3), 341-355.
- Kendirli, S. ve Nergiz, G. (2023). Investigation of the causal relationship between cryptocurrency prices and the gross domestic products of BRICS countries: Bitcoin example. *Quatrade Journal of Complex Systems in Social Sciences*, 5(2), 151–158.
- Kubar, Y. ve Toprak, Y. (2021). Bitcoin ve altcoin’ler arasındaki ilişkinin Granger nedensellik testi ile analizi. *JOEEP: Journal of Emerging Economies and Policy*, 6(1), 233–247.
- Kutlu, B. ve Badur, B. (2009). Yapay sinir ağları ile borsa endeksi tahmini. *Yönetim - İstanbul Üniversitesi İşletme Fakültesi İşletme İktisadi Enstitüsü Dergisi*, 20(63).
- Liu, J., Julaiti, J. ve Gou, S. (2024). Decomposing interconnectedness: A study of cryptocurrency spillover effects in global financial markets. *Finance Research Letters*, 61, 104950.
- Milutinović, M. (2018). Cryptocurrency. *Ekonomika – Časopis za Ekonomsku Teoriju i Praksu i Društvena Pitanja*, (1), 105–122.
- Mnif, E., Salhi, B., Mouakha, K., ve Jarbouï, A. (2022). Investor behavior and cryptocurrency market bubbles during the COVID-19 pandemic. *Review of Behavioral Finance*, 14(4), 491-507.
- Nakamoto, S. (2008). *Bitcoin: A peer-to-peer electronic cash system*.
- Nas, S., ve Ünal, A. E. (2023). Bitcoin fiyat değişimlerinin makine öğrenmesi yöntemi ile tahmin edilmesi. *İşletme Araştırmaları Dergisi*, 15(4), 2597-2608.
- Omane-Adjepong, M. ve Alagidede, I. P. (2019). Multiresolution analysis and spillovers of major cryptocurrency markets. *Research in International Business and Finance*, 49, 191–206.
- Özcan, E. F., ve Yenikaya, M. A. (2025). Haber tabanlı duygu analizinin bitcoin fiyat tahminine etkisi: makine öğrenmesi yaklaşımlarıyla bir karşılaştırma. *Ekinoks Ekonomi İşletme ve Siyasal Çalışmalar Dergisi*, 12(2), 24-42.
- Özekenci, S. Y. (2023). Kripto para birimlerinin Bitcoin ile etkileşiminin incelenmesi: Toda-Yamamoto nedensellik testi. *Karamanoğlu Mehmetbey Üniversitesi Sosyal ve Ekonomik Araştırmalar Dergisi*, 25(45), 1193–1209.
- Pacelli, V., Di Tommaso, C., Foglia, M. ve Ingannamorte, S. (2025). Cryptocurrencies and systemic risk: The spillover effects between cryptocurrency and financial markets. In *Systemic Risk and Complex Networks in Modern Financial Systems* (s. 343).
- Pan, L., Vaughan, O. ve Wright, C. S. (2023). A private and efficient triple-entry accounting protocol on Bitcoin. *Journal of Risk and Financial Management*, 16(9), 400.
- Qarni, M. O., Gulzar, S., Fatima, S. T., Khan, M. J. ve Shafi, K. (2019). Inter-markets volatility spillover in US Bitcoin and financial markets. *Journal of Business Economics and Management*, 20(4), 694–714.
- Ranjan, S., Kayal, P., ve Saraf, M. (2023). Bitcoin price prediction: A machine learning sample dimension approach. *Computational Economics*, 61(4), 1617-1636.
- Riedl, R., Gschwentner, L. ve Krueger, F. (2024). Determinants of trust in Bitcoin: Literature review and results of a survey study. *Telematics and Informatics Reports*, 100132.
- Segendorf, B. (2014). What is Bitcoin? *Sveriges Riksbank Economic Review*, 2014, 2–71.
- Siddique, I. M., Siddique, A. A., Smith, E. D. ve Molla, S. (2024). Assessing the sustainability of Bitcoin mining: Comparative review of renewable energy sources. *Journal of Alternative and Renewable Energy Sources*, 10(1), 1–12.
- Sifat, I. M., Mohamad, A. ve Shariff, M. S. B. M. (2019). Lead-lag relationship between Bitcoin and Ethereum: Evidence

from hourly and daily data. *Research in International Business and Finance*, 50, 306–321.

Soltani, H., Taleb, J., & Boujelbène Abbes, M. (2025). The directional spillover effects and time-frequency nexus between stock markets, cryptocurrency, and investor sentiment during the COVID-19 pandemic. *European Journal of Management and Business Economics*, 34(1), 23–46.

Soylu, K. P., Okur, M., Çatıkkaş, Ö. ve Altıntığ, Z. A. (2020). Long memory in the volatility of selected cryptocurrencies: Bitcoin, Ethereum and Ripple. *Journal of Risk and Financial Management*, 13(6), 107.

Terraza, V., Boru İpek, A., ve Rounaghi, M. M. (2024). The nexus between the volatility of Bitcoin, gold, and American stock markets during the COVID-19 pandemic: evidence from VAR-DCC-EGARCH and ANN models. *Financial Innovation*, 10(1), 22.

Upadhyay, H. J., Raichura, B. ve Shah, R. (2018). Interrelation of Bitcoin with Euro, Gold, Nifty, Crude oil and Ripple: A causality test. *Sankalpa*, 8(2), 24–27.

Ur Rehman, M. H., Salah, K., Damiani, E. ve Svetinovic, D. (2019). Trust in blockchain cryptocurrency ecosystem. *IEEE Transactions on Engineering Management*, 67(4), 1196–1212.

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

Vranken, H. (2017). Sustainability of Bitcoin and blockchains. *Current Opinion in Environmental Sustainability*, 28, 1–9.

Wang, X., Chen, X. ve Zhao, P. (2020). The relationship between Bitcoin and stock market. *International Journal of Operations Research and Information Systems (IJORIS)*, 11(2), 22–35.

Wattenhofer, R. (2016). *The science of the blockchain*. CreateSpace Independent Publishing Platform.

Wu, B., Xu, J., Zhang, Y., Liu, B., Gong, Y. ve Huang, J. (2024). Integration of computer networks and artificial neural networks for an AI-based network operator. *arXiv preprint arXiv:2407.01541*.

Zhang, S. ve Mani, G. (2021). Popular cryptoassets (Bitcoin, Ethereum, and Dogecoin), gold, and their relationships: Volatility and correlation modeling. *Data Science and Management*, 4, 30–39.

Zhang, S., Xu, Q., Ding, X. ve Han, K. (2025). Risk spillover between cryptocurrencies and traditional currencies: An analysis based on neural network quantile regression. *Physica A: Statistical Mechanics and its Applications*, 130560.

Zhou, F. (2024). Cryptocurrency: A new player or a new crisis in financial markets? Evolutionary analysis of association and risk spillover based on network science. *Physica A: Statistical Mechanics and its Applications*, 648, 129955.