

PAPER DETAILS

TITLE: Çok Katmanli Yapay Sinir Aglari Yöntemi ile Altin Fiyatlarinin Tahmini

AUTHORS: Yakup SÖYLEMEZ

PAGES: 271-291

ORIGINAL PDF URL: <https://dergipark.org.tr/tr/download/article-file/955163>

Çok Katmanlı Yapay Sinir Ağları Yöntemi ile Altın Fiyatlarının Tahmini

Yakup SÖYLEMEZ (<https://orcid.org/0000-0002-6185-3192>), Department of Accounting and Tax, Zonguldak Bülent Ecevit University, Turkey; e-mail: yakup.soylez@beun.edu.tr

Prediction of Gold Prices Using Multilayer Artificial Neural Networks Method

Abstract

The accurate estimation of financial time series provides both investment opportunities and hedging financial assets to those who take positions in financial markets. In this context, it is extremely important to estimate the price of gold, which is an important investment instrument. The research aims to estimate gold prices with various input variables the day before by using artificial neural networks method. In the study, gold prices between 11.03.2014-10.31.2019 are estimated by multi-layer artificial neural networks using variables of Brent oil prices, VIX index, Dow Jones Index and US Dollar index. As a result of the research, there is a model that best estimates (98,44%) gold prices.

Keywords : Artificial Intelligence, Artificial Neural Networks, Financial Investment Instruments, Gold Prices, Time Series Estimation.

JEL Classification Codes : C22, C45, G17, G23.

Öz

Finansal zaman serilerinin doğru tahmin edilebilmesi finansal piyasalarda pozisyon alanlara hem yatırım fırsatları sunabilmekte hem de finansal varlıklarını hedge edebilme olanağı sağlamaktadır. Bu kapsamda önemli bir yatırım aracı olan altının fiyatının tahmin edilebilmesi son derece önemlidir. Araştırma yapay sinir ağları yöntemini kullanarak altın fiyatlarının bir gün önceki çeşitli girdi değişkenleriyle tahmin edilebilmesini amaçlamaktadır. Uygulama kısmında 03.11.2014-31.10.2019 tarihleri arasında oluşan altın fiyatları, Brent petrol fiyatları, VIX endeksi, Dow Jones Endeksi ve ABD Dolar endeksi değişkenleri kullanılarak çok katmanlı yapay sinir ağları ile tahmin edilmektedir. Araştırma sonucunda altın fiyatlarını en iyi tahmin eden model bulunmuş ve altın fiyatları %98,44 oranında doğru tahmin edilmiştir.

Anahtar Sözcükler : Yapay Zekâ, Yapay Sinir Ağları, Finansal Yatırım Araçları, Altın Fiyatları, Zaman Serilerinin Tahmini.

1. Giriş

Başta akıllı bilgisayar programları olmak üzere akıllı makineler üretme bilimi ve mühendisliği (McCarthy, 2007: 2) olarak tanımlanabilen yapay zekâ uygulamaları gittikçe artan uygulama alanları ile yeni bir çağın önemli simgeleri olarak karşımıza çıkmaktadır. Bu nedenle teknoloji geleceği her yönden şekillendirdiği gibi gelecekle ilgili bazı tahminlerin yapılmasında da önemli rol oynamaktadır. Özellikle finans alanında tahmin ve danışmanlık hizmetlerinin verilmesinde uzman sistemlerin yaygın olarak kullanılmaya başlandığı görülmektedir. Bu araştırmanın konusunu da bu kapsamda finansal zaman serilerinin yapay zekâ teknolojileri ile öngörülüp öngörülemediği oluşturmaktadır. Bu amaçla uzman sistemler içerisinde sayılan yapay sinir ağları modeli ile altın fiyatlarının tahmin edilip edilemeyeceği konusunda bir araştırma yapılmış ve araştırma bulgu ve sonuçları ortaya konulmuştur.

Altın hem ticarete konu olması hem mücevher olarak kullanılabilir olması hem de sahibinin ve sürümünü yapanın belirlenememesi bakımından çeşitli zamanlarda çeşitli amaçlarla ve farklı kişi ve kurumlar tarafından talep edilmektedir. Özellikle finansal ve politik kriz dönemlerinde altına olan talep oldukça yüksek olmakta ve altın fiyatları da bu doğrultuda dalgalanma göstermektedir. Örneğin "İran İslam Devrimi" sonrasında rejim karşıtları ve şah yanlıları ülkeden yurtdışına iltica ederken mal varlıklarını en fazla altın şeklinde dışarı çıkarmayı tercih etmişlerdir. Bunun sebebi altının kolayca şekil alabilecek ve çeşitli şekillerde taşınabilecek bir metal olmasından kaynaklanmaktadır. Araştırmanın kapsamının çok değerli ve spekülatif bir finansal ürün olan altının fiyatının yapay sinir ağları modeli kullanılarak tahmin edilip edilemeyeceği olarak belirlenmesinin nedenlerinden biri de bu olarak görülebilir. Araştırma ile ilgili genel konsept verilmeden önce dünya ticaretinde altının önemi ve günümüzde kullanıma biçimi ve yoğunluğu hakkında bilgi verilmesinin araştırmanın teorik altyapısının oluşturulmasında uygun olacağı düşünülmektedir.


Tüm tarihsel dönemler esas alındığında ticaret için son derece önemli olan altının uluslararası bir değer standardı olarak kullanılmaya başlanması 1870 yılına denk gelmektedir. Söz konusu standart I. Dünya Savaşı'nın başladığı 1914 yılına kadar geçerliliğini korumuş ve 1920'li yıllarda başlayan ekonomik sıkıntılara kadar varlığını sürdürmüştür (Cooper vd., 1982: 3). Bu dönemden sonra ülkeler arasında çıkan finansman farklılıkları standardın uygulanması olasılığını ortadan kaldırmıştır. Bununla birlikte altının uluslararası ticarete kullanımı farklı fiyat rejimleri ile devam etmiştir.

Altın standardının başarısız olması dünya ekonomik sistemini yeni bir kur rejimi aramaya yönlendirmiştir. Nitekim 1944 yılında ABD'nin New Hampshire eyaletinin Bretton-Woods kasabasında 44 ülkeden gelen katılımcıların oluşturduğu delegasyon yeni bir uluslararası para sistemi konusunda anlaşmaya varmıştır. Konferans aynı zamanda Uluslararası Para Fonu'nun kurulduğu ve Dünya Bankası'nın temellerinin atıldığı bir toplantı olma özelliği taşımaktadır. Toplantıda alınan en önemli karar ise tüm ülke paralarının dolar esas alınarak değerlendirilmesi ve doların değerinin de 1 ons altın 35 \$ olarak belirlenmesi suretiyle sabitlenmesi olmuştur. Söz konusu para sistemi 1971 yılına kadar geçerliliğini sürdürmesine rağmen (Ghizoni, <<https://www.federalreservehistory.org/>>),

05.12.2019) 1973 petrol krizi döneminde tüm dünyada sabit kur uygulamasından vazgeçilmesi altın fiyatlarının dalgalanması durumunu da beraberinde getirmiştir (Karataş & Ürkmez, 2013: 559). Bu tarihten sonra dünya para sistemi dalgalı kur rejimine göre belirlenmiştir. Altın fiyatları da bu tarihten sonra hem politik hem de finansal gelişmelerden etkilenmektedir. Bu nedenle altın fiyatları körfez savaşı, 2008 finansal krizi, "Arap baharı" gibi politik ve finansal gelişmeler çerçevesinde dalgalanmalar göstermiştir. Daha yalın bir ifade ile altın fiyatları çeşitli faktörlerden etkilenmekle beraber arz ve talebe bağlı olarak piyasada ortaya çıkmaktadır. Bu noktada altın arzı ve talebi kavramlarının açıklanmasında fayda bulunmaktadır.

Madencilik faaliyetleri sonucunda çıkarılan altının yanında altın cinsinden verilen krediler ile merkez bankası tarafından yapılan satışlar ve hurda ya da ikinci el altının toplanması sonucu oluşan değere altın arzı adı verilmektedir (Topçu, 2010: 4). Grafik 1'de 2010-2018 yılları arasında dünya altın arzı ve arz ile karşılaştırma yapılabilmesi amacıyla Londra Külçe Pazarı Birliği (London Bullion Market Association- LBMA)'nin açıkladığı altın fiyatı verilmiştir. LBMA başta Londra Borsası olmak üzere birçok borsa haricinde tezgahüstü bir piyasa olarak altın fiyatlarının alıcı ve satıcı arasında şeffaf olarak belirlendiği bir piyasadır. Söz konusu piyasaya belirli bir hacmin üzerindeki üreticiler üye olarak kabul edilmekte olup piyasanın uluslararası kurumlar için kredibilitesi oldukça yüksektir.

Grafik: 1
Dünya Altın Arzı ve Fiyatı (2010-2018)




Kaynak: Dünya Altın Konseyi, <<https://www.gold.org>>, 01.12.2019.

Grafik 1 incelendiğinde dünya altın arzının 2010-2018 yılları arasında sabit bir seyir gösterdiği söylenebilir. Bu veri dikkate alındığında dünya altın arzının altın fiyatlarını doğrudan etkilemediği sonucuna ulaşılabilir. Örneğin 2012 yılında dünya altın arzı yaklaşık 4600 ton olarak gerçekleşmiş ve aynı yıl piyasa fiyatı ortalama olarak ons cinsinde 1669 \$ olarak oluşmuştur. 2013 yılında ise dünya altın arzı yaklaşık 4359 ton olarak gerçekleşirken

piyasa fiyatı ons cinsinden ortalama olarak 1411 \$ olmuştur. Genel ekonomi teorisine göre bir malın arzı ile fiyatı arasında ters yönlü bir ilişki bulunmaktadır. Yani altın arzı arttığında altın fiyatının düşmesi; altın arzı azaldığında ise altın fiyatının yükselmesi beklenmektedir. Ancak 2012 ve 2013 yılındaki veriler esas alındığında bu tür bir ilişkiden söz etmek mümkün değildir. Altın arzı ve fiyatı arasındaki ilişkinin, diğer yıllara bakıldığında da doğrusal modellerle açıklanamayacağı görülmektedir. Diğer taraftan Grafik 1’de hurda altın olarak tanımlanan geri dönüştürülmüş altının arz miktarı ile fiyat arasında genel ekonomi teorisine uygun bir ilişki olduğundan bahsedilebilir. Hurda altın arzının yüksek olduğu yılları takip eden yılda altın fiyatlarında görece düşüş gözlemlenirken; hurda altın arzının düşük olduğu yılları takip eden yıllarda altın fiyatlarında yükselme gözlemlenmiştir. Bununla beraber bu ilişki grafikte analiz edilemeyecek kadar karmaşıktır. Dolayısıyla ilişkinin ortaya konulması için daha etkin ekonometrik modellere ihtiyaç duyulmaktadır.

Dünya altın piyasaları için altın arzı kadar önemli olan bir diğer konunun da altın talebi olduğu açıktır. Kişi ve kurumlar çeşitli nedenlerle altın talep edebilmektedir. Bu nedenler mücevher üretimi için girdi olması, teknolojide altın kullanımı, yatırım amacıyla altın talebi ve merkez bankasının rezerv değer olarak altın talep etmesi olarak sıralanabilir. Altın bilinen kullanım alanlarının yanında teknoloji alanında da yaygın olarak kullanılmaktadır. Altın elektrik-elektronik, uzay ve havacılık, inşaat ve tıp sektörü gibi birçok alanda teknoloji temelli malların üretimi için kullanılmaktadır. Altının teknoloji alanındaki kullanım miktarı yıllar itibarıyla fazla değişmeyerek dünya genelinde 400 ton civarında kalmaktadır.

Grafik: 2
Dünya Altın Talebi ve Fiyatı (2010-2018)



Kaynak: Dünya Altın Konseyi, <<https://www.gold.org>>, 01.12.2019.

Grafik 2’de 2010-2018 yılları arasındaki dünya altın talebi ve LBMA fiyatı görülmektedir. Söz konusu grafiğe göre dünya altın talebinin önemli bir kısmını mücevher

yapımına yönelik talep oluşturmaktadır. İkinci sırada en yüksek talep ise yatırım amaçlı olarak ortaya çıkmaktadır. Yatırım amacıyla altın talebinin azaldığı dönemlerde, örneğin 2013, 2014 ve 2015 yılları, mücevher yapımı amacıyla altın talebinin arttığı görülmektedir. Bunun aksi durumda yine Grafik 2'de açıkça görülmektedir. Bu durum ekonomik daralma dönemlerinde ve daralma beklenen dönemlerde altının yatırım aracı olarak daha fazla kullanıldığını, ekonomik genişleme dönemlerinde ise altının tüketim amacıyla kullanıldığını ortaya koymaktadır. Bununla birlikte tüm dönemlerde altın talebinin belirli bir düzeyin üzerinde olduğu da görülmektedir. Grafik 2'den elde edilebilecek bir diğer bilgi ise merkez bankalarının, bir diğer ifadeyle para otoritelerinin rezerv olarak önemli miktarda (yıllık ortalama 400-450 ton) altın talebinde bulunmalarıdır. Bu durum altının bütün para birimleri karşısında gücünü koruyabilmesinden kaynaklanmaktadır.


Grafik 2'de altın talebi ve LBMA tarafından ilan edilen altın fiyatı dikkate alındığında doğrusal olmayan ancak aynı yönde olan bir ilişki gözlemlenebilmektedir. Bir başka ifadeyle altın talebinin arttığı dönemlerde piyasa fiyatı yükselmekte, altın talebinin azaldığı dönemlerde ise piyasa fiyatının azaldığı gözlemlenmektedir. Bu durum genel ekonomi teorisine uygun gözükmeyle birlikte kabaca bir analizin yapıldığının da belirtilmesi gerekir. Burada rasyonel bir değerlendirmenin gerçekleştirilebilmesi için altın talebi ile altın fiyatları arasındaki ilişkinin istatistiki ve ekonometrik tekniklerden faydalanılarak açıklanması gerekmektedir.

Dünya altın arz ve talebi beraber değerlendirildiğinde arz ve talep miktarlarının birbirine çok yakın olduğu görülmektedir. Grafik 1 ve Grafik 2 değerlendirildiğinde, örneğin 2018 yılında toplam altın arzı 4677 ton iken aynı yıl toplam altın talebi 4396 ton olarak gerçekleşmektedir. Talebin arzdan az olduğu durumlarda fiyatın azalması beklenmektedir. Ancak hemen hemen her yıl bu durum gerçekleşmesine rağmen altın fiyatlarının söz konusu duruma bağlı olarak değişmediği de dikkate alınmalıdır. Dolayısıyla altın fiyatlarının arz ve talep dışında diğer politik ve makroekonomik değişkenlere bağlı olarak değiştiği de yapılacak analizlerde dikkate alınmalıdır. Bu analizler yapılırken dikkate alınması gereken bir diğer nokta ise altının yapısı gereği kayıt dışı bir unsur olarak kullanılmaya müsait olmasıdır. Bu durumun bir örneği olarak Burkina Faso'da madencilik bakanı olan Omarou Idani ülkeden çıkarılan her 9,5 ton altının yalnızca 400 kilogramının deklare edildiğini iddia etmektedir (<<https://tr.euronews.com/2019/04/24/afrika-dan-her-yil-milyarlarca-dolarlik-altin-yasa-disi-yollarla-cikariliyor>>, 01.12.2019). Dolayısıyla çeşitli kurumlar tarafından açıklanan arz ve talep miktarlarının gerçeği tam olarak yansıtmadığı konusunda büyük bir kuşku bulunmaktadır. Sonuç olarak arz ve talep rakamlarının altın fiyatları analizinde yeterli olmadığı ortaya çıkmaktadır.

Altın arz ve talebi ile ilgili kayıt dışılıkla alakalı değerlendirmeler bir tarafa bırakılırsa 2018 yılında dünya altın üretiminin yaklaşık %25'inin Çin tarafından yapıldığı görülmektedir. Grafik 3 incelendiğinde 404 ton üretimle ilk sırada yer alan Çin'i 315 tonla Avustralya ve 297 ton ile Rusya izlemektedir. Türkiye'nin 2018 yılındaki altın üretiminin ise 25 ton civarında gerçekleştiği görülmektedir. Bu bakımdan Türkiye dünyanın önemli altın üreticileri arasında yer almamaktadır. Buna karşılık Türkiye dünyanın önemli altın ithalatçıları arasında da yer almaktadır. Enerji ve Tabii Kaynaklar Bakanlığı verilerine göre

2018 yılında Türkiye’nin altın ithalatı 324 ton olarak gerçekleşmiştir (<<https://www.enerji.gov.tr/tr-TR/Sayfalar/Altin>>, 01.10.2019). Türkiye gerek yatırım gerekse mücevher olarak önemli miktarda altın talebi olan bir ülke olmasının yanında Merkez Bankası’nın da rezerv varlık olarak altın bulundurduğu bir ülkedir.

Grafik: 3
Altın Üretimi (2018)




Kaynak: Dünya Altın Konseyi, <<https://www.gold.org>>, 01.12.2019.

Grafik 4’te 2010-2018 yılları arasındaki bazı ülkelerin merkez bankalarının altın rezervi miktar (ton) cinsinden görülmektedir. Grafik 4’ten de görülebileceği üzere ABD merkez bankası FED (Federal Reserve) önemli miktarda (8133 ton) altın rezervi bulundurmaktadır. Dünyanın toplam merkez bankaları altın rezervinin 32000 ton civarında olduğu dikkate alındığında, ABD merkez bankasının en yüksek altın rezerv miktarına sahip olduğu açıkça görülmektedir. ABD’yi altın rezerv miktarı bakımından ortalama 3400 tonluk miktarla Almanya takip etmektedir. Bir diğer gelişmiş ülke olan Birleşik Krallık ise ortalama 310 tonluk miktarla bu iki merkez bankasından ayrılmaktadır. Bununla birlikte bütün batılı gelişmiş ekonomilerin merkez bankalarının yıllar itibarıyla altın rezerv miktarlarının sabit kaldığı görülmektedir.

Çin ve Rusya gibi Şanghay İşbirliği Örgütü’nün en önemli üyelerinin merkez bankalarının altın rezervlerine bakıldığında ise yıllar itibarıyla dalgalanma göze çarpmaktadır. Bu durum Çin ve Rusya merkez bankalarının dolara bağımlılıklarını azaltma politikaları ile uyumlu görünmektedir. Son dönemde özellikle Rusya merkez bankası toplam rezervleri içerisinde altının payını da önemli ölçüde arttırmıştır. Ancak bu oransal artışın Çin için söylenilmesi mümkün görünmemektedir. Bu durum Grafik 5’te görülebilmektedir.

Grafik: 4
Merkez Bankası Altın Rezervi 2010-2018 (Ton)



Kaynak: Dünya Altın Konseyi, <<https://www.gold.org>>, 01.12.2019.


Türkiye Cumhuriyet Merkez Bankası (TCMB)'nin altın rezervlerinin 2010-2018 yılları arasındaki miktarı da Grafik 4'ten görülebilmektedir. Grafik 4 incelendiğinde TCMB'nin altın rezervleri 2017 yılına kadar sabit kalmış (116 ton), 2017 yılında altın rezervi 202 tona 2018 yılında ise 253 tona çıkmıştır. TCMB 2019 yılında da altın rezervlerini arttırmaya devam etmiştir.

Dünya Altın Konseyi'nin verileri incelendiğinde 2019 yılının üçüncü çeyreğinde TCMB dünyanın en çok altın alan merkez bankası olmuştur. 2019 yılının üçüncü çeyrek sonu itibarıyla TCMB altın rezervleri 385,5 tona çıkmıştır. Bu durum Türkiye'nin 2016-2019 yılları arasında maruz kaldığı politik ve ekonomik saldırı ve sıkıntılarla (15 Temmuz Darbe Girişimi, 2018 Ağustos Dolar Krizi, S-400 Krizi, Suriye'de terör unsurlarına karşı yapılan operasyonlar vb.) bağlantılı olarak değerlendirilebilir. Türkiye, özellikle 2018 Ağustos ayında maruz kaldığı dolar manipülasyonuna karşı önlem olarak merkez bankasının altın rezerv miktarını artırma yoluna gitmektedir. Bu suretle ABD dolarına olan bağımlılık tıpkı Rusya ve Çin gibi azaltılarak olası bir ekonomik ve/veya politik krizin etkilerinin azaltılması hedeflenmektedir.

Merkez bankalarının altın rezerv miktarları kadar önemli olan bir diğer gösterge ise tutmuş oldukları altın rezervlerinin ABD doları cinsinden değerlerinin toplam rezervlerinin ABD doları cinsinden değerine oranıdır. Grafik 5'te 2010-2018 yılları arasındaki söz konusu oran seçilmiş ülkelerin merkez bankaları için verilmektedir. Grafik 5 incelendiğinde ABD ve Almanya merkez bankalarının toplam rezervlerinin yaklaşık %70'ini altın cinsinden tutmakta oldukları görülmektedir. Bu iki gelişmiş ülke için altının toplam rezerv içindeki payı neredeyse sabit kalmış olmasına rağmen Birleşik Krallık için altın rezerv oranı 2010 yılında %14,3 iken 2018 yılında yarıya düşerek %7,39 olarak gerçekleşmiştir. Bu durumun

en önemli nedenlerinden biri bankanın altın rezervlerinin önemli bir kısmını yirmi yıl önce İşçi Partisi dönemi Maliye Bakanı Gordon Brown tarafından gelişmekte olan ülkelere satılmasının etkileri olarak gösterilmektedir (<<https://www.independent.co.uk/voices/gordon-brown-gold-reserves-sold-economy-analysis-financial-bullion-a8909611.html>>, 08.12.2019). Dolayısıyla Birleşik Krallık yıllar itibarıyla altın rezerv oranını azaltan nadir ülkelerden biri olarak değerlendirilebilir.

Grafik: 5
Merkez Bankası Altın Rezervi 2010-2018 (%)



Kaynak: Dünya Altın Konseyi, <<https://www.gold.org>>, 01.12.2019.

Grafik 5 incelendiğinde Çin'in altın rezerv oranının artmasına rağmen önemli bir artışın olmadığından bahsedilebilir. Altın rezerv oranında asıl ciddi artışın 2013 yılından itibaren Rusya'da ve 2016 yılından itibaren Türkiye'de olduğu görülmektedir. Rusya Merkez Bankası'nın 2013 yılında %7,86 olan altın rezerv oranı 2018 yılında %18,54 oranında gerçekleşmiştir. TCMB ise altın rezervi konusundaki politikasını yukarıda da detaylı olarak anlatıldığı üzere 2016 yılından itibaren çeşitli politik ve ekonomik olaylar çerçevesinde değiştirmiş ve altın rezervini önemli ölçüde arttırmıştır. Bu kapsamda 2016 yılında %4,43 olan altın rezerv oranı 2018 yılının sonunda %12,51 oranına yükselmiştir.

Grafik 4 ve Grafik 5 birlikte değerlendirildiğinde Dünya'nın batılı gelişmiş ülkelerinin altın rezervlerini miktar ve oran cinsinden sabit tuttuğu, Şanghay İş Birliği Örgütü'ne üye gelişmiş iki ülkenin altın rezervini arttırdığı, özellikle Rusya'nın bu konuda Çin'den de ayrıştığı değerlendirilmektedir. Türkiye özelinde gelişmekte olan ülke merkez bankalarının ise altını ABD doları dahil diğer para birimlerinin kur dalgalanmalarına ve olası manipülasyonlara karşı bir hedging aracı olarak arttırdıkları görülmektedir. Dolayısıyla altın hem uluslararası ticaretin hem de uluslararası para politikasının önemli bir aktörü olmaya devam etmektedir. Bu kapsamda altın fiyatlarının ve en azından altın fiyatlarının yönünün

önceden tahmin edilebilmesi politik ve ekonomik olarak önem kazanmaktadır. Söz konusu tahmin çabaları finans piyasaları ve kuruluşları için de hayati önem taşımaktadır.

Yukarıda sıralanan nedenlerle çalışmada altının bir gün önceki çeşitli (n) girdilerle $n+1$. gündeki fiyatının tahmin edilmesi amaçlanmaktadır. Çalışma kapsamında altın fiyatlarının tahmin edilmesi için yapay zekâ yöntemlerinden biri olan çok katmanlı yapay sinir ağları yöntemi kullanılmaktadır. Çalışmada girdi değişkenleri olarak Brent Petrol fiyatı, VIX (Volatility Index) endeksi, Dow Jones endeksi ve ABD Dolar endeksi kullanılmaktadır. Bu girdi değişkenleri içerisinde VIX endeksi ilk kez bu çalışma kapsamında yapay sinir ağları ile altın fiyatlarının tahmininde girdi değişkeni olarak kullanılmıştır. Çalışmanın literatüre katkısı bu endeksin kullanılarak altın fiyatlarının tahmin edilmesi olarak kabul edilebilir. Araştırma kapsamındaki değişkenlerin 3.11.2014-31.10.2019 tarihleri arasındaki değerleri normalize edilerek tahmin çalışmasına dahil edilmiştir. Çalışmanın budan sonraki kısmında konu ile alakalı literatür taramasına yer verilmiş, ardından çok katmanlı yapay sinir ağları yöntemi anlatılmıştır. Çalışmanın son iki kısmında ise bulgular tartışılarak sonuç ve önerilere yer verilmiştir.

2. Literatür Araştırması

Finansal zaman serilerinin yapay sinir ağları metodu ile tahmini konusunda yapılan çalışmalar son yıllarda finans literatüründe geniş yer bulmaktadır. Bu nedenle literatür taraması yapılırken altın fiyatları ile ilgili çalışmalar esas alınmıştır. Bu çerçevede akademik çalışmalar karşılaştırmalı olarak açıklanarak bu çalışmanın diğer çalışmalardan farkı ve literatüre olan katkısı ortaya konulmaya çalışılmıştır.

Altın fiyatlarının tahminine yönelik olarak yapılan çalışmalarda temel olarak çeşitli finansal göstergeler girdi değişkeni olarak kullanılarak altın fiyatlarının tahmin edilmesine çalışılmaktadır. Bu çerçevede Adem vd. (2017) tarafından girdi değişkeni olarak Brent petrol fiyatı, ABD doları, BIST100 endeksi, TCMB haftalık faiz oranı, gümüş ve bakır fiyatları kullanılarak altın fiyatları tahmin edilmeye çalışılmıştır. Araştırmada çok katmanlı yapay sinir ağları yöntemi kullanılmış ve ortalama olarak %98,17 oranında altın fiyatlarının doğru tahmin edilebileceğine dair bulgular elde edilmiştir. Çelik ve Başarır (2017), Adem vd. (2017) tarafından gerçekleştirilen çalışmaya oranla daha geniş bir değişken havuzu kullanarak altın, gümüş, platin ve paladyum fiyatlarını tahmin etmeye çalışmışlardır. Çalışmada girdi değişkenleri olarak Brent Petrol, doğal gaz, 30 yıllık bono, 10 yıllık bono, 5 yıllık bono, S&P 500, Nasdaq, Dow Jones, FTSE100, DAX, CAC40, SMI, NIKKEI, HANH, SEND ve Euro/Dolar rakamları kullanılmış ve tahmin çalışmasında kabul edilebilir hata oranına ulaşılabilmektedir. Benzer bir çalışmada Yüksel ve Akkoç (2016) gümüş fiyatları, Brent Petrol fiyatları, ABD doları/ EURO paritesi, EuroNext100 endeksi, Dow Jones Endeksi, 13 hafta vadeli ABD bonosu faiz oranı ve ABD TÜFE endeksini girdi değişkeni olarak kullanarak yapay sinir ağları modeli ile altın fiyatlarını tahmin etmiş ve çok yüksek oranda altın fiyatlarının tahmin edilebileceğine dair bulgular elde etmişlerdir. Aynı model ve değişkenler kullanılarak Öndes ve Oğuzlar (2019) tarafından da bir çalışma gerçekleştirilmiş, çalışmada benzer bulgular elde edilmiştir.

Kocatepe ve Yıldız (2016) ise gram altın fiyatlarının değişim yönünün ham petrol fiyatı, dolar endeksi, dolar kuru, Standard&Poor's 500 endeksi, BIST100 endeksi, Türkiye enflasyon, tahvil ve faiz oranları, ABD enflasyon, tahvil ve faiz oranları, gümüş ve bakır fiyatları değişkenlerini kullanarak %75,24 oranında başarılı olarak tahmin edilebileceğine dair bulgular elde eden bir çalışma gerçekleştirmiştir.

Literatürde altın fiyatlarının tahmininde yapay sinir ağlarının yanında başka modellerinde kullanıldığı çalışmalar da bulunmaktadır. Bu kapsamda Benli ve Yıldız (2014) tarafından gerçekleştirilen çalışmada çeşitli modellerin altın fiyatlarının tahminindeki performansları karşılaştırılmıştır. Çalışmada yapay sinir ağları modeli Holt'un doğrusal trend yöntemine göre daha başarılı bulunurken, ARIMA modeline göre daha az başarılı olduğuna dair kanıtlar elde edilmiştir. Benzer şekilde Mombeini ve Yazdani-Chamzini (2015) yapay sinir ağları modeli ile ARIMA modelini altın fiyatları tahmin performansı açısından karşılaştırmıştır. Bu çalışmada Benli ve Yıldız (2014) tarafından yapılan çalışmanın aksine yapay sinir ağları modelinin altın fiyatları tahmininde ARIMA modeline kıyasla daha başarılı olduğuna dair bulgular elde edilmiştir. Benzer bulgular Chen vd. (2014) tarafından yapılan çalışmada altın futures kontratlar için elde edilmiştir.

Altın getirilerinin tahmininde Markov zinciri ile yapay sinir ağlarının entegre edildiği çalışmalar da yapılmıştır. Kılıç (2013) bu kapsamda yapmış olduğu çalışmada altın getirilerini Markov zinciri ile modellemiş ve bir sonraki gündeki getiri yönünü tahmin etmiştir. Çalışmada yaklaşık olarak yüzde 70 oranında başarılı sınıflandırma gerçekleştirilmiştir. Bir diğer çalışmada ise Paksoy (2017) altın getirilerinin tahmininde Markov zinciri ile yapay sinir ağları modelini entegre eden bir model önerisi getirmiş, ancak çalışma diğer tahmin çalışmalarına göre sınıflandırmada daha az başarılı bulgular elde etmiştir. Söz konusu iki çalışmayla benzerlik gösteren bir diğer çalışmada Çam ve Kılıç (2018) altın getirilerini yapay sinir ağları modeli ile tahmin etmiş, tahmin edilen getirilerin farklı rejimlerdeki geçiş olasılıklarını Markov zincirini kullanarak hesaplamış ve %70 oranında başarılı tahmin gerçekleştirilebileceği ortaya konulmuştur.

Literatürde çeşitli modellerin yapay sinir ağları modeli ile karşılaştırılmasının yanı sıra hibrit yapay sinir ağları modelleri ile geleneksel yapay sinir ağları modellerinin karşılaştırıldığı çalışmalar da yer almaktadır. Geleneksel yapay sinir ağları modeli ile genetik algoritmaya dayalı yapay sinir ağları modelini karşılaştırdıkları çalışmada Khamis ve Yee (2018) hibrit modelin altın fiyatları tahmini için geleneksel modele kıyasla daha etkin sonuçlar verdiğine dair bulgular elde etmişlerdir. Kristjanpoller ve Minutolo (2015) ise GARCH modelleri ile yapay sinir ağlarını entegre ederek ANN-GARCH isimli yeni bir model önermişlerdir. Bu modele dayalı olarak yapılan altın fiyatları tahmininde Euro/Dolar ve Yen/Dolar döviz kurları, DJI ve FTSE borsa endeksleri ve petrol fiyatları girdi değişkeni olarak kullanılmış ve geleneksel GARCH yöntemlerine göre %25 daha başarılı tahmin sonuçları elde edilmiştir. Bir başka çalışmada ise Kangarani-Farahani ve Mehralian (2013) üç farklı yapay sinir ağları modelini karşılaştırarak altın fiyatları için en uygun tahmin modelinin ortaya konulmasına çalışmışlardır. Çalışmada geleneksel yapay sinir ağları modeli, uyarlanabilir bulanık yapay sinir ağları modeli ve bu iki modelden oluşturulan hibrit

bir model karşılaştırılmış ve en uygun tahmin modelinin uyarlanabilir bulanık yapay sinir ağları modeli olduğuna dair bulgular elde edilmiştir.

Alameer vd. (2019) yapmış oldukları çalışmada balina optimizasyon algoritmasına dayanan yeni bir yapay sinir ağı modeli önererek altın fiyatlarını tahmin etmeye çalışmıştır. Metodun gri kurt algoritması, genetik algoritma ve parçacık algoritması gibi birçok metottan altın fiyatları tahmininde daha üstün olduğuna dair bulgular elde edilmiştir. Hafezi ve Akhavan (2018) ise BAT adı verilen meta-sezgisel algoritmaya dayanan yapay sinir ağları, ARIMA, ANFIS, çok katmanlı yapay sinir ağları, genelleştirilmiş regresyon sinir ağları ve radyal temel fonksiyon modellerinin altın fiyatlarının tahmin performanslarını karşılaştırmışlardır. Araştırma en uygun modelin meta sezgisel yöntem olduğuna dair bulgular elde etmiştir. Bir diğer çalışmada Aydın ve Çavdar (2015) ABD Doları-Türk Lirası (USD / TRY) döviz kuru, altın fiyatları ve Borsa İstanbul (BIST) 100 endeksi arasındaki ilişkiye dayanarak yapay sinir ağları ve VAR modellerinin bu değişkenleri tahmin etme yeteneklerini karşılaştırmışlardır. Araştırmada yapay sinir ağları modellerinin daha üstün tahmin yeteneğine sahip olduğuna dair bulgular elde edilmiştir.

Yukarıda altın fiyatlarının ve getiri yönünün tahminine ilişkin yapay sinir ağları modelinin kullanıldığı çalışmalara yer verilmiştir. Bu araştırma kapsamında da çeşitli girdi değişkenleri kullanılarak yapay sinir ağları modeli ile altın fiyatları tahmin edilmektedir. Bu girdi değişkenleri Brent Petrol fiyatı, VIX endeksi, Dow Jones endeksi ve ABD Dolar endeksi olarak belirlenmiştir. Çalışmada diğer çalışmalardan farklı olarak VIX endeksi girdi değişkeni olarak kullanılmaktadır. VIX endeksi korku endeksi olarak bilinmekte ve piyasadaki korku ve endişeyi yansıtmaktadır. Bu endeks tüm yatırımcılar tarafından piyasanın yönünün tahmin edilebilmesi amacıyla kullanılmaktadır. Dolayısıyla altın fiyatlarının tahmini için korku endeksinin girdi değişkeni olarak kullanılması altın fiyatlarında meydana gelebilecek volatilitayı açıklaması bakımından önemli görülmektedir. Çalışmanın literatüre katkısı bu kapsamda ele alınabilir.

3. Araştırmanın Yöntemi


Finansal zaman serilerinin tahmininde kullanılan birçok model olduğu bu araştırmanın giriş ve literatür kısmında özellikle vurgulanmıştır. Bu modeller içerisinde yer alan yapay zekâ uygulamaları kapsamındaki yapay sinir ağları modeli son dönemde finansal zaman serilerinin analizinde yaygın olarak kullanılmaktadır. Bu araştırmanın uygulama kısmında da altın fiyatlarının tahmininde çok katmanlı yapay sinir ağları modeli kullanılmaktadır.

Yapay sinir ağları modelinin temelinde insan beynindeki nöronların oluşturduğu biyolojik sinir ağlarının çalışma mekanizmasının taklit edilmesi bulunmaktadır. Biyolojik nöral sistemde bir nesne veya imge girdi olarak alınarak nöronlar tarafından bir proses içerisinde anlamlı çıktılara dönüştürülmektedir. Benzer şekilde yapay sinir ağları da çeşitli girdileri ve nöronları esas alarak bir proses içerisinde bilgiler veya diğer bir ifade ile çıktılar üretmektedir (Lin, 2009: 3510). Bu açıklamadan da açıkça görüleceği üzere yapay sinir ağları modeli diğer istatistiki modellerden farklı olarak girdi ve çıktı değişkenleri arasında

doğrudan ilişki kurmamakta, bunun yerine girdi değişkenlerini bir proses içerisinde değiştirerek ve eğiterek çıktılara dönüştürmektedir.

Çok katmanlı yapay sinir ağları modelinde kategorik öğrenme tabakaları girdi, çıktı ve gizli tabakalar olmak üzere üç kısımdan oluşmakta (Etheridge & Sriram, 1997: 236) ve bu tabakaların her birinde nöron adı verilen işlem birimleri ve bu işlem birimlerinin birbiriyle ilişkilerini düzenleyen yapılar bulunmaktadır (Lee & Chen, 2005: 745). Yapay sinir ağları algoritmasının giriş katmanı olan ilk katmanındaki nöronlara giriş nöronları denilmektedir. Son katman olan çıkış katmanında ise çıkış nöron veya nöronları yer almaktadır. Yapay sinir ağları algoritmasındaki orta katman girdi ve çıktı nöronlarını barındırmadığı için ise gizli katman denilmektedir. Bununla birlikte bazı ağların tek bazılarının ise birden fazla gizli katmanı bulunmaktadır. Birden fazla gizli katmanı olan ağlara çok katmanlı yapay sinir ağları denilmektedir (Nielsen, 2015: 11). Basit bir çok katmanlı yapay sinir ağları modeli ve modele ilişkin matematiksel formülasyon Şekil 1 ve devamındaki formüller ile ifade edilebilir (Krenker, 2011: 7).

Şekil: 1
Yapay Sinir Ağları Mimarisi



Kaynak: Krenker, 2011: 7.

$$n_1 = F_1(w_1x_1 + b_1) \quad (1)$$

$$n_2 = F_2(w_2x_2 + b_2) \quad (2)$$

$$n_3 = F_3(w_3x_3 + b_3) \quad (3)$$

$$n_4 = F_4(w_4x_4 + b_4) \quad (4)$$

$$m_1 = F_4(q_1n_1 + q_2n_2 + b_4) \quad (5)$$

$$m_2 = F_5(q_3n_3 + q_4n_4 + b_5) \quad (6)$$

$$y = F_6(r_1m_1 + r_2m_2 + b_6) \quad (7)$$

$$y = F_6 \left[\begin{array}{l} r_1(F_4[q_1F_1[w_1x_1 + b_1] + q_2F_2[w_2x_2 + b_2]] + b_4) + \dots \\ \dots + r_2(F_5[q_3F_2[w_2x_2 + b_2] + q_4F_3[w_3x_3 + b_3]] + b_5) + b_6 \end{array} \right] \quad (8)$$

Genel yapısı bu kısımda verilen yapay sinir ağları modelinin oluşturulması ve çalıştırılması bazı aşamaların izlenmesi suretiyle gerçekleştirilmektedir. Bu aşamalar kısaca şu şekilde ifade edilebilmektedir (Benli & Yıldız, 2014: 217):

Değişkenlerin Normalize Edilmesi: Yapay sinir ağları algoritmasının oluşturulabilmesi için yapılacak analize ilişkin girdi değişkenlerinin $[0,1]$ aralığına getirilerek normalize edilmesi gerekmektedir. Böylece tüm değişkenler karşılaştırılabilir olarak analize dahil edilebilecektir. Bu analizde x_i girdi değişkeni olmak üzere girdi değişkenleri Formül 9 kullanılarak normalize edilmektedir.

$$x'_i = \frac{x_i - \min(x_i)}{\max(x_i) - \min(x_i)} \quad (9)$$

Verilerin Organize Edilmesi: Değişkenlere ait verilerin eğitim, geçerlilik ve test setlerine ayrılması aşamasıdır. Bu aşamada verilerin belirli yüzdeleri kullanılarak eğitim, geçerlilik ve test setleri oluşturulur.

Modelleme Yapılması: Yapay sinir ağları modeline ait algoritmanın oluşturulması aşamasıdır. Bu aşamada algorithma kullanılacak girdi, gizli ve çıktı tabaka sayıları, bu tabakaların her birinde yer alacak nöron sayıları, öğrenme algoritması, algorithma ait parametreler ve performans ölçüleri belirlenmektedir. Burada gizli tabakada bir veya birden fazla katman oluşturulabilir.

Algorithma ve Veri Setine En Uygun Ağırlık Değerlerinin Belirlenmesi: Bir önceki aşamada belirlenen öğrenme algoritmasının eğitim seti üzerine uygulanması suretiyle en iyi ağırlık değerleri bulunarak yapay sinir ağları modelinin çıktı değerleri elde edilmektedir.

Algoritma Çıktılarına İlişkin Performans Ölçütlerinin Hesaplanması: Analizin bu aşamasında yapay sinir ağlarına ilişkin test setine ait öngörüler elde edilir. Öngörüler ile test setindeki verilerin arasındaki farka dayalı olarak performans ölçütü hesaplanır.

Tahmin: Bu aşamada en iyi ağırlık değerleri kullanılarak gelecek için zaman serilerinin tahmini yerine getirilir.

4. Araştırmanın Bulguları ve Tartışma

Yapay zekâ yöntemleri ve bu yöntemlerin içerisinde araştırmanın konusunu oluşturan yapay sinir ağları ile ilgili genel teorik çerçeve ve tartışma oluşturulduktan sonra konunun esasını oluşturan uygulama gerçekleştirilerek bu uygulama ile ilgili ampirik bulgular ortaya konularak tartışılmıştır. Dolayısıyla bu kısımda belirli bir sistematik içerisinde öncelikle veri seti tanımlarak tanımlayıcı istatistikler analiz edilmiş, sonraki kısımda ise araştırmanın bulguları tartışılmıştır.

4.1. Veri Seti

Bu araştırma kapsamında yapılan uygulamada bir yapay zekâ uygulaması olan çok katmanlı yapay sinir ağları modelinin altın fiyatlarını tahmin edebilme yeteneğinin test edilebilmesi için 03.11.2014-31.10.2019 tarihleri arasındaki 1258 günlük veri seti kullanılmıştır. Tablo 1’de bu araştırma kapsamında kullanılan değişkenler veri sıklıkları, simgeleri ve verilerin alındığı kaynak gösterilmiştir.

Araştırmada kullanılan değişkenlerin tanımlayıcı istatistikleri analiz edilmeden önce bu değişkenlerin kullanılma sebepleri üzerinde durulmasında fayda bulunmaktadır. Petrol fiyatları ile altın arasındaki ilişkinin var olduğunu gösteren çalışmalar literatürde geniş çapta yer almaktadır (Topçu, 2010; Adem vd., 2017; Çelik & Başarır, 2017; Yüksel & Akkoç, 2016; Mombeini & Yazdani-Chamzini, 2015; Kristjanpoller & Minutolo, 2015). Literatürde yer alan çalışmaların büyük bir çoğunluğunda petrol fiyatları değişkeni olarak dünya petrol anlaşmalarının üçte ikisini elinde tutan BO (Brent Oil - Brent Petrol) esas alınmıştır. Bu araştırmada da benzer şekilde altın fiyatları üzerindeki etkisi dikkate alınarak BO fiyatları bağımsız değişken olarak esas alınmıştır.

Tablo: 1
Araştırmada Kullanılan Değişkenler

	Değişken	Birim	Veri Sıklığı	Simgesi	Kaynak
1	Altın	\$/Ons	Günlük	G	< https://tr.investing.com/ >
2	Brent Petrol	\$/Varil	Günlük	BO	< https://tr.investing.com/ >
3	VIX	-	Günlük	VIX	< https://tr.investing.com/ >
4	Dow Jones Endeksi	\$	Günlük	DJI	< https://tr.investing.com/ >
5	ABD Dolar Endeksi	-	Günlük	DXY	< https://tr.investing.com/ >

DJI değişkeni de finansal zaman serilerinin analizinde sıklıkla başvurulmuş bir değişkendir. Literatürde altın fiyatlarının tahmininde uluslararası bir endeks olarak kabul edilen DJI değişkeni yaygın olarak kullanılmaktadır (Çelik & Başarır, 2017; Yüksel & Akkoç, 2016; Kristjanpoller & Minutolo, 2015; Topçu, 2010). Araştırmada kullanılan bir başka değişken olan DXY ise Euro, Japon Yeni, Sterlin, Kanada Doları, İsveç Kronu ve İsviçre Frangı olmak üzere ABD’nin en yüksek ticaret hacmini gerçekleştirdiği altı para birimine karşı ABD dolarının değerini gösteren endeks olarak tanımlanmaktadır. DXY değişkeni de altın fiyatlarının açıklanmasında sıklıkla kullanılmaktadır (Mombeini & Yazdani-Chamzini, 2015; Topçu, 2010). Bu araştırmada da uluslararası ticaretin en yüksek hacimli para birimi olan ABD dolarının yine yüksek ticaret hacmine sahip para birimleri

karşısındaki değerini gösteren DXY değişkeni altın fiyatlarını tahmin etmek için kullanılmaktadır.

Bu araştırma kapsamında kullanılan bir diğer değişken olan VIX değişkeni korku endeksi olarak bilinmektedir. Bu endeks piyasalar ile ilgili korku ve endişeyi göstermekte olan bir endekstir. VIX, 1993 yılında Şikago Ticaret Borsası (Chicago Board of Trade-CBOE) tarafından oluşturulmuştur ve literatürde altın fiyatları ve altın yatırımcısının davranışları ile ilgili olarak geniş bir yer bulmuştur (Basher & Sadorsky, 2016; Jubinski & Lipton, 2013; Cohen & Qadan, 2010). Buna karşın yapay sinir ağları ile altın fiyatlarının tahmini çalışmalarında, bu araştırma kapsamında yapılan literatür araştırmasında VIX değişkeninin kullanıldığına rastlanmamıştır. Bununla birlikte hem nedensellik hem de volatilité modellerinin kullanıldığı literatür dikkate alındığında altın fiyatları tahmininde VIX endeksinin kullanılmasının önemli olduğu açıkça görülmektedir. Bu nedenle çalışmada bu değişken veri setine dahil edilmiştir.

Tablo: 2
Tanımlayıcı İstatistikler

	G	BO	VIX	DJI	DXY
Gözlem Sayısı	1258	1258	1258	1258	1258
Ortalama	1303.03	58.0977	15.1843	21401.8	957.693
Medyan	1302.45	57.4600	14.0850	20950.7	960.015
Maksimum	1560.40	86.2900	40.7400	27359.1	103.288
Minimum	1090.50	27.8800	9.14000	15660.1	87.092
St.Sapma	85.2762	11.4500	4.26134	3602.54	30.4114
Skewness	0.20759	0.03996	1.46033	0.14449	-0.39530
Kurtosis	3.59188	2.57024	6.15080	1.43166	3.28468
Jarque-Bera	27.3989	10.0155	967.497	133.304	37.0124
Olasılık	0.00000	0.00668	0.00000	0.00000	0.00000

Tüm ampirik analizlerde uygulama gerçekleştirilmeden önce verilerin genel yapısının analiz edilebilmesi amacıyla tanımlayıcı istatistiklere yer verilmektedir. Bu doğrultuda Tablo 2’de araştırma kapsamında kullanılan değişkenlere ilişkin tanımlayıcı istatistiklere yer verilmiştir. Tablodaki maksimum ve minimum değerler incelendiğinde araştırmanın yapıldığı dönemde bütün değişkenlerin dalgalanma yaşadığı görülmektedir. Buna karşın tablodaki Jarque-Bera değerleri ve normallik varsayımına ilişkin olasılık değerleri incelendiğinde analize konu değişkenlerin normallik varsayımını sağladıkları görülmektedir.


4.2. Bulgular ve Tartışma

Bu çalışma kapsamında yapılan araştırmada yapay sinir ağları modelinin oluşturulması ve geliştirilmesinde MATLAB R2019a programı kullanılmıştır. Çalışmada yapılan analizde toplam 1258 günlük veri kullanılmıştır. Bu veri setinin %70’i (880 adet) eğitim; %15’i (189 adet) geçerlilik ve %15’i (189 adet) test için kullanılmıştır. Çalışmada oluşturulan veri seti 2 ile 20 arasında nöron kullanılarak oluşturulan modeller aracılığıyla yapay sinir ağları kurulmak suretiyle test edilmiştir. Araştırma kapsamında oluşturulan yapay sinir ağları modelinde ileri beslemeli geri yayılım (Feed-forward backprop) tipi ağ kullanılmıştır. Araştırmada öğrenme algoritması olarak Levenberg-Marquardt eğitim

algoritması seçilmiştir. Yapay sinir ağı modellerinin performans fonksiyonu olarak MSE (Mean Square Error- Hata Kareler Ortalaması) kullanılmaktadır.

Yapay sinir ağlarının oluşturulmasında en önemli konulardan biri de katman sayısının belirlenmesidir. Yapay sinir ağları analizlerinde toplam katman sayısının 1 (bir) eksiği kadar gizli katman yer almaktadır. Katman sayısının belirlenmesinde genel bir kural bulunmamakla birlikte genellikle “geometrik piramit kuralı” kullanılmaktadır (Masters, 1993). Gizli katman sayısının üst sınırı bu kurala göre girdi sayısının 2 (iki) katı olarak belirlenmektedir (Denton, 1995). Asgari gizli katman sayısı ise girdi değişkeni sayısı ile çıktı değişkeni sayısının çarpımının karakökü ile belirlenmektedir. Tüm bu açıklamalar çerçevesinde uygulamadaki gizli katman sayısı 2 ile 8 arasında belirlenmelidir. Bu çerçevede uygulamada gizli katman sayısı 2 ile 8 arasında denenmiş ve optimal sonucu veren gizli katman sayısı 4 olarak belirlenmiştir. Son olarak araştırmada daha önceki kısımlarda da belirtildiği gibi çok katmanlı yapay sinir ağları modeli kullanılarak analiz yapılmaktadır. Şekil 2’de araştırmada kullanılan 4 (dört) katmanlı ve 2 nöron sayılı olarak oluşturulan yapay sinir ağları mimarisi gösterilmektedir.

Şekil: 2
Araştırmada Kullanılan Yapay Sinir Ağı Mimarisi Örneği



Şekil 2’de mimari olarak gösterilen 4 katmanlı yapay sinir ağı MATLAB R2019a programı kullanılarak 2 ile 20 nöron sayısı arasında sınanmış ve oluşturulan modellerin çıktıları Tablo 3’de olduğu şekliyle elde edilmiştir. Çıktılar analiz edilirken en iyi test sonucunu veren modelin optimal model olduğu düşünülmüştür. Ayrıca performans değerlendirme kriterleri de program kapsamında çoklu olarak sınanmış ve en optimal performans değerlendirme kriterinin hata kareler ortalamasını esas alan MSE kriteri olduğu tespit edilmiştir. Tablo 3 incelendiğinde altın fiyatlarının tahmini için en iyi test sonucunu veren nöron sayısının 20 olduğu anlaşılmıştır. Tablo 3’de açıkça tespit edileceği üzere nöron sayısı değiştikçe yapay sinir ağının performansı değiştiği görülmüş fakat performans çıktıları ile nöron sayısı arasında doğrusal bir ilişki bulunamamıştır. Uygulamadan elde edilen bir diğer çıktı ise girdi değişkenlerinin bütün nöron sayılarında çıktı değişkenini


başarılı bir şekilde ifade etmiş olduğudur. Bununla birlikte yukarıda da bahsedildiği üzere en başarılı model 4 katmanlı ve 20 nöronlu oluşan model olarak tespit edilmiştir.

Tablo: 3
Gizli Katmandaki Nöron Sayıları ve R Değerleri


Nöron Sayısı	Eğitim Seti	Geçerlilik Seti	Test Seti
2N	0,97217	0,96372	0,96623
3N	0,97032	0,95365	0,96687
4N	0,97179	0,97336	0,97603
5N	0,97965	0,97626	0,97184
6N	0,98230	0,97467	0,98008
7N	0,97541	0,97499	0,97186
8N	0,97929	0,97815	0,97268
9N	0,98035	0,98281	0,98327
10N	0,98444	0,98615	0,98159
11N	0,97839	0,97619	0,98203
12N	0,97953	0,98212	0,97993
13N	0,97179	0,97985	0,97217
14N	0,97661	0,97564	0,97244
15N	0,97604	0,96944	0,97070
16N	0,96823	0,97413	0,97520
17N	0,97718	0,97634	0,96556
18N	0,97157	0,98029	0,97768
19N	0,96718	0,97141	0,97099
20N	0,98013	0,98083	0,98444

Uygulama çerçevesinde elde edilen 20 nöronlu en başarılı modele ait çıktılar Grafik 6'da çıktı olarak sunulmuştur. Grafik 6 analiz edilirken veri setinin %70 eğitim, %15 geçerlilik ve %15 test aşamaları için ayrıştırıldığına vurgulanmasında fayda bulunmaktadır. Buna göre modelin verileri yakalama yeteneği görsel olarak tespit edilebilmektedir. Eğitim için kullanılan verilerin modelin oluşturduğu doğruya yakınlık derecesi %98,01; geçerlilik için kullanılan verilerin modelin oluşturduğu doğruya yakınlık derecesi %98,08 ve test için kullanılan verilerin modelin oluşturduğu doğruya yakınlık derecesi ise %98,44 olarak tespit edilmiştir. Böylece oluşturulan yapay sinir ağının yüksek başarı yüzdesi ile altın fiyatlarını tahmin edebildiği görülmüştür.

Grafik: 6
Yapay Sinir Ağı Çıktıları (20 Nöron)



Grafik: 7
Gerçekleşen ve Tahmin Edilen Altın Fiyatları



5. Sonuç ve Öneriler

Yapay zekâ uygulamaları son yıllarda bilimin çeşitli alanlarında yaygın olarak kullanılmaktadır. Özellikle Endüstri 4.0'ın oluşturduğu ortam yapay zekânın ve yapay zekâyâ bağlı olarak ortaya çıkan uygulamaların gün geçtikçe geliştirilmesine ve farklı alanlarda uygulama imkânı bulmasına yol açmaktadır. Bu kapsamda işletmecilik ve finans alanı da yapay zekâ uygulamalarını etkin bir şekilde kullanmaya başlamıştır. Bunun temel sebebi finansal piyasaların oldukça değişken yapısı ve birçok değişkenden etkilenme kapasitesidir. Finansal piyasa paydaşları açısından bu değişkenlik hem bir fırsat hem de büyük bir risk olarak karşımıza çıkmaktadır. Bu doğrultuda geliştirilecek yapay zekâ uygulamaları bir taraftan yatırımcılara piyasa fırsatlarını yakalama imkânı verirken diğer taraftan piyasada oluşabilecek risklere karşı hedge imkânı verebilmelidir. Yapay zekâ uygulamalarının bir kısmı geçmiş piyasa verilerini analiz ederek geleceğe ilişkin finansal zaman serilerini yakalayabilme imkânı sunmaktadır.

Altın fiyatlarını tahmin edebilmek amacıyla bu çalışmada bir yapay zekâ uygulaması olan yapay sinir ağları kullanılmıştır. Araştırma kapsamında 03.11.2014-31.10.2019 tarihleri arasında oluşan altın fiyatları, Brent petrol, VIX endeksi, Dow Jones Endeksi ve ABD Dolar Endeksi girdi değişkeni olarak kullanılarak tahmin edilmeye çalışılmıştır. Söz konusu tahmin çalışması çeşitli nöron sayılarını esas alan 4 katmanlı bir yapay sinir ağı oluşturularak gerçekleştirilmiştir. Yapılan analiz sonucunda altın fiyatlarını en başarılı olarak tahmin eden modelin 20 nöron sayısına sahip model olduğu tespit edilmiştir. Bu model altın fiyatlarını %98,44 oranında başarı ile tahmin etmiştir.

Çalışma Benli ve Yıldız (2014), Mombeini ve Yazdani-Chamzini (2015), Yüksel ve Akkoç (2016), Adem vd. (2017) ve Çelik ve Başarır (2017) tarafından yapılan çalışmalara benzer şekilde altın fiyatların oldukça yüksek bir oranda tahmin etmeyi başarmıştır. Çalışma bu başarı yüzdesini söz konusu çalışmaların birçoğundan daha az değişken kullanarak gerçekleştirmiştir. Bunun sebebinin çalışmanın diğer çalışmalardan farklı olarak VIX endeksini de değişken setinde kullanmasının olduğu düşünülmektedir. Ayrıca yapılan çalışmada altın fiyatları Kılıç (2013), Kocatepe ve Yıldız (2016) ve Çam ve Kılıç (2018) tarafından yapılan çalışmalardan daha yüksek bir yüzdeyle tahmin edilmiştir. Bu durumun sebebinin araştırmalarda farklı değişkenlerin kullanılması olduğu düşünülmektedir.

Bu çalışma kapsamında yapılan araştırma diğer çalışmalardan farklı olarak altın fiyatlarının tahmininde girdi değişkeni olarak korku endeksi olarak bilinen VIX endeksini kullanmıştır. VIX endeksi finansal piyasalarda ortaya çıkan riskleri göstermesi bakımından finansal varlıkların ticaretinde pozisyon alacak yatırımcılar için oldukça değerli bilgiler sunmaktadır. Yapılan araştırmanın bu yönde literatüre katkı sunduğu değerlendirilmektedir. Bu araştırma sonrası çalışmalarda farklı finansal girdiler kullanılarak ve farklı zaman serileri tahmin edilerek çalışmanın geliştirilebileceği de değerlendirilmektedir.

Kaynaklar

- Adem, K. & O. Comert & N. Zengin & M. Hekim (2017), “Prediction of Gold Prices Using Artificial Neural Networks”, *Uluslararası Mühendislik Araştırma ve Geliştirme Dergisi*, 9(3), 83-89.
- Alameer, Z. & M.A. Elaziz & A.A. Ewees & H. Ye & Z. Jianhua (2019), “Forecasting Gold Price Fluctuations Using Improved Multilayer Perceptron Neural Network and Whale Optimization Algorithm”, *Resources Policy*, 61, 250-260.
- Aydın, A.D. & S.C. Çavdar (2015), “Comparison of Prediction Performances of Artificial Neural Network (ANN) and Vector Autoregressive (VAR) Models by Using the Macroeconomic Variables of Gold Prices, Borsa İstanbul (BIST) 100 Index and US Dollar-Turkish Lira (USD/TRY) Exchange Rates”, *Procedia Economics and Finance*, 30, 3-14.
- Basher, S.A. & P. Sadorsky (2016), “Hedging Emerging Market Stock Prices with Oil, Gold, VIX, and Bonds: A Comparison between DCC, ADCC and GO-GARCH”, *Energy Economics*, 54, 235-247.
- Benli, Y.K. & A. Yıldız (2014), “Altın Fiyatının Zaman Serisi Yöntemleri ve Yapay Sinir Ağları ile Öngörüsü”, *Dumlupınar Üniversitesi Sosyal Bilimler Dergisi*, 42(2), 213-224.
- Cohen, G. & M. Qadan (2010), “Is Gold Still a Shelter to Fear”, *American Journal of Social and Management Sciences*, 1(1), 39-43.
- Cooper, R.N. & R. Dornbusch & R.E. Hall (1982), “The Gold Standard: Historical Facts and Future Prospects”, *Brookings Papers on Economic Activity*, 1982(1), 1-56.
- Çam, S. & S.B. Kılıç (2018), “Altın Fiyatı Günlük Getirilerinin Yapay Sinir Ağları Algoritması ve Markov Zincirleri Modelleri ile Tahmini”, *Uluslararası İktisadi ve İdari İncelemeler Dergisi*, Özel, (18), 681-694.
- Çelik, U. & Ç. Başarır (2017), “The Prediction of Precious Metal Prices via Artificial Neural Network by Using RapidMiner”, *Alphanumeric Journal*, 5(1), 45-54.
- Denton, J.W. (1995), “How Good Are Neural Networks for Causal Forecasting?”, *The Journal of Business Forecasting*, 14(2), 17.
- Etheridge, H.L. & R.S. Sriram (1997), “A Comparison of the Relative Costs of Financial Distress Models: Artificial Neural Networks, Logit and Multivariate Discriminant Analysis”, *Intelligent Systems in Accounting, Finance & Management*, 6(3), 235-248.
- Ghizoni (N/A), <https://www.federalreservehistory.org/essays/bretton_woods_created>, 05.12.2019.
- Hafezi, R. & A. Akhavan (2018), “Forecasting Gold Price Changes: Application of an Equipped Artificial Neural Network”, *AUT Journal of Modeling and Simulation*, 50(1), 71-82.
- Jubinski, D. & A.F. Lipton (2013), “VIX, Gold, Silver, and Oil: How do Commodities React to Financial Market Volatility?”, *Journal of Accounting and Finance*, 13(1), 70-88.
- Kangarani-Farahani, M. & S. Mehralian (2013), “Comparison between Artificial Neural Network and Neuro-fuzzy for Gold Price Prediction”, içinde: *13th Iranian Conference on Fuzzy Systems (IFSC)*, IEEE, 1-5.
- Karataş, T. & E. Ürkmez (2013), “Küresel Kriz Sürecinde Altın Fiyatlarını Etkileyen Dinamikler”, içinde: *International Conference on Eurasian Economies*.
- Khamis, A. & P.H. Yee (2018), “A Hybrid Model of Artificial Neural Network and Genetic Algorithm in Forecasting Gold Price”, *European Journal of Engineering Research and Science*, 3(6), 10-14.

- Kılıç, S.B. (2013), "Predicting the Direction of Gold Price Returns: Integrating Composite Artificial Neural Network Models by Markov Chain Process", *Çukurova Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 17(2), 15-28.
- Kocatepe, C.İ. & O. Yıldız (2016), "Ekonomik Endeksler Kullanılarak Türkiye'deki Altın Fiyatındaki Değişim Yönünün Yapay Sinir Ağları ile Tahmini", *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 4(3).
- Krenker, A. & J. Bešter & A. Kos (2011), *Artificial Neural Networks-Methodological Advances and Biomedical Applications: Introduction to the Artificial Neural Networks*, Consalta doo Faculty of Electrical Engineering, University of Ljubljana Slovenia.
- Kristjanpoller, W. & M.C. Minutolo (2015), "Gold Price Volatility: A Forecasting Approach Using the Artificial Neural Network-GARCH Model", *Expert Systems with Applications*, 42(20), 7245-7251.
- Lee, T.S. & I.F. Chen (2005), "A Two-stage Hybrid Credit Scoring Model Using Artificial Neural Networks and Multivariate Adaptive Regression Splines", *Expert Systems with Applications*, 28(4), 743-752.
- Lin, T.-H. (2009), "A Cross Model Study of Corporate Financial Distress Prediction in Taiwan: Multiple Discriminant Analysis, Logit, Probit and Neural Networks Models", *Neurocomputing*, 72, 3507-3516.
- Masters, T. (1993), *Practical Neural Network Recipes in C++*, Academic Press, San Diego, California.
- McCarthy, J. (2007), "From Here to Human-level AI", *Artificial Intelligence*, 171(18), 1174-1182.
- Mombeini, H. & A. Yazdani-Chamzini (2015), "Modeling Gold Price via Artificial Neural Network", *Journal of Economics, Business and Management*, 3(7), 699-703.
- Nielsen, M.A. (2015), *Neural Networks and Deep Learning (Vol. 25)*, San Francisco, CA, USA: Determination Press.
- Öndes, H. & A. Oğuzlar (2019), "Yapay Sinir Ağlarıyla Altın (Tl/Kg) Fiyatı Tahmini", *Akademik Bakış Uluslararası Hakemli Sosyal Bilimler Dergisi*, (72), 249-262.
- Paksoy, S. (2017), "Hibrit Markov Zinciri Süreci ile Altın Getirisinin Öngörülmesi", *Bolu Abant İzzet Baysal Üniversitesi Sosyal Bilimler Enstitüsü Dergisi*, 17(1), 29-49.
- Topçu, A. (2010), "Altın Fiyatlarını Etkileyen Faktörler", *SPK Araştırma Raporu*, Ankara.
- Yüksel, R. & S. Akkoç (2016), "Altın Fiyatlarının Yapay Sinir Ağları ile Tahmini ve Bir Uygulama", *Dogus University Journal*, 17(1).
- <<https://tr.euronews.com/2019/04/24/afrika-dan-her-yil-milyarlarca-dolarlik-altin-yasa-disi-yollarla-cikariliyor>>, 01.12.2019.
- <<https://www.enerji.gov.tr/tr-TR/Sayfalar/Altin>>, 01.10.2019.
- <<https://www.gold.org>>, 01.12.2019.
- <<https://www.independent.co.uk/voices/gordon-brown-gold-reserves-sold-economy-analysis-financial-bullion-a8909611.html>>, 08.12.2019.

