



YAPAY SİNİR AĞLARIYLA ALTIN (TL/KG) FİYATI TAHMİNİ

Hakan ÖNDES*

Ayşe OĞUZLAR^{†**}

ÖZ

Finansal varlıkların değerleri, farklı indekslerin değerleri gibi vasıfların öngörüsü finans alanında olabildiğince önem göstermekte ve bu konuda epey zamanda farklı modeller elde edilmektedir. Doğrusal ya da doğrusal olmayan regresyon analizi, geleneksel zaman serileri analizi ve volatilité benzeri modellerin beraberinde son zamanlarda yapay sinir ağı serileri öngörmeye oldukça sık kullanılmaya başlamıştır. Yapılan çalışmalarda yapay sinir ağlarının geleneksel zaman serisi tekniklerine nazaran daha olumlu sonuçlar verdiği tespit edilmiştir.

Bu çalışmada altının kapanış değerlerini yapay sinir ağı ile tahmin etmek amacıyla, altın fiyatları ile etkileşim içinde olacağı düşünülen Brent petrol ve gümüş piyasa değerleri, ABD doları/ EUR paritesi, EuroNext100 indeksi, Amerika Dow Jones İndeksi verileri modelleme aşamasında test edilmiştir. Yapay sinir ağı ile oluşturulan modelde saptanan tahmin neticeleri altının gerçek kapanış değerleri baz alınarak çeşitli performans ölçütleri ile karşılaştırılmıştır.

Elde edilen sonuçlar yapay sinir ağlarının altın fiyatlarını öngörmeye %81,43'lük başarıya ulaştığı tespit edilmiştir. Yapılan geçerlilik çözümlemesinin sonuçları incelendiğinde altın fiyatlarını belirleyen etmenlerin başında gümüş fiyatları, EUR/USD paritesi ve Brent petrol piyasa değerlerinin olduğu saptanmıştır.

Anahtar Kelimeler: Yapay Sinir Ağları, Performans Kriterleri, Altın Fiyatı Tahmini, Altın Fiyatlarını Etkileyen Etmenler, Geçerlilik Analizi

ESTIMATED GOLD PRICE (TL / KG) WITH ARTIFICIAL NEURAL NETWORKS

ABSTRACT

Estimates of variables such as the prices of financial assets, the values of various indices are very important in the field of finance and various models have been developed in this issue for a long time. Linear and non-linear regression analysis, traditional time series analysis and volatility, as well as models such as artificial neural networks have recently been widely used for predicting series. It has been found that artificial neural networks give more successful results than traditional time series techniques.

In this study, in order to predict the closing prices of gold with artificial neural networks, models were established using silver prices, Brent oil prices, US dollar / EUR parity, EuroNext100 index, US Dow Jones Index, which are variables that are thought to affect gold prices. Estimation results obtained by modeling with artificial neural networks were compared with actual values and performance criteria were recalculated.

It has been determined that in the light of the results, artificial neural networks achieved 81.43% success rate of gold prices. When the results of the validity analysis are reevaluated, it is determined that silver prices, EUR / USD parity and Brent oil prices are the leading factors affecting gold prices.

Keywords: Artificial Neural Network, Performance Criteria, Gold Prices Prediction, Effects That Affecting The Gold Prices, Validity Analysis

* Arş. Gör., Bandırma Onyedi Eylül Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Ekonometri Bölümü, hondes@bandirma.edu.tr

** Prof. Dr., Uludağ Üniversitesi, İktisadi ve İdari Bilimler Fakültesi Ekonometri Bölümü, ayseog@uludag.edu.tr



GİRİŞ

Yüzyıllar boyu zenginliğin simgesi olan altın yatırım araçları içerisinde en etkili konumda yer almaktadır. Altının her şartta, her durumda rahatlıkla paraya dönüştürülebilir olması kuşkusuz bu durumun en önemli nedenidir. Ayrıca son zamanlarda ekonomide meydana gelen kriz, siyasi belirsizlikler ve yaşanan felaketler alternatif yatırım araçlarına (bono, tahvil, döviz vb.) olan güveni azaltarak altının değerini arttırmıştır (Kırılıoğlu ve Fidan, 2006:40-50).

Altın çoğunlukla gelişmiş ülkelerde ziynet eşyası olarak değerlendirilirken, az gelişmiş veya gelişmekte olan ülkelerde yatırım hedefiyle kullanılmaktadır. Bu durumun nedeni ulusal paranın devamlı değer kaybetmesi ve özellikle gelişmekte olan ülkelerde insanların varlıklarını enflasyona yönelik muhafaza etmesi amacıyla altında değerlendirmesinden kaynaklanmaktadır (Dünya Bülteni, 2008, 12.10.2017).

Altın fiyatlarını ekonometrik modellerle açıklamaya ilişkin literatürde pek çok araştırma bulunmaktadır. Genel durum değerlendirildiğinde bu araştırmalar üç başlık altında derlenebilir. İlki altın fiyatındaki meydana gelen değişiklikleri makroekonomik değişkenler yardımıyla açıklayan çalışmalardır (Balı ve Cinel, 2011; Toraman vd, 2011; Aksoy ve Topçu, 2013; Elmas ve Polat, 2014). İkincisi altın fiyatlarındaki değişim yönüne oynaklığa ilişkin yapılan çalışmalardır (Vural, 2003; Aksu, 2008; Cihangir ve Uğurlu, 2013; Kocatepe ve Yıldız, 2016). Üçüncü grupta ise altının enflasyona karşı koruma aracı olarak inceleyen çalışmalar bulunmaktadır (Ghosh vd, 2004; Ranson, 2005 a,b).

Ekonomide altın fiyatları gümüş, petrol fiyatları, uluslararası piyasadaki dalgalanmalardan, hazine bonusu, borsa bileşik indeksi ve enflasyondan etkilenebilir. Bu verilerin zaman içindeki değişimi olasılıksal bir yapıya sahip olduğundan çözümlenmesinde geleneksel zaman serisi yaklaşımları yetersiz kalmaktadır (Öztürk ve Açıkalin, 2008: 38). Bu sebeple araştırmacılar daha iyi sonuçlar elde edebilmek için literatürde farklı yöntemleri denemiştir.

Büyük veri setlerinin varlığı, hızlı öğrenme ve test etmede algoritma mantığının kullanılması, araştırmacıların doğrusal olmayan model ve yöntemlere ilgi duymalarını sağlamıştır (Yüksel ve Akkoç, 2016:40). Bu anlamda yapay sinir ağları (YSA) hem eğrisel hem de doğrusal yapıyı öğrenebilme yeteneğine olduğundan daha iyi öngörü sonuçları vermektedir. Yapay sinir ağlarının temel mantığını oluşturan unsur insan beyninin (nöronların) veri tasarım kabiliyetinin optimal düzeyde taklit etmeye uğraşmasıdır.

Araştırmanın temel hedefi altın fiyatlarının (TL/kg) YSA ile tahmin edilmesidir. YSA denklemlerinin oluşturulmasında farklı deneysel nöronlardan yararlanarak en yararlı model elde edilmiştir. En yararlı model için Ortalama Hata Karelerinin Karekökü, Determinasyon Katsayısı, Ortalama Mutlak Hata, Ortalama Mutlak Yüzde Hata kriterleri mukayese edilerek optimum neticeye ulaşılmak istenmiştir.

Araştırmanın daha sonraki aşamalarında öncelikle altın fiyatlarının belirlenmesi adına gerçekleştirilen çalışmalara yer verilmiştir. Sonraki aşamada YSA yapısı tanıtılmış ve



ardından veriler ve yöntem hakkında bilgi verilip uygulama sonuçları aktarılmıştır. Sonuç bölümünde uygulama sonuçları yorumlanmıştır.

LİTERATÜR

Literatürün kapsamı altın fiyatı ve fiyat değişimi tahmininde yapay sinir ağları ile sınırlandırılmıştır. Bu anlamda Mirmirani ve Li (2004) yaptıkları çalışmada NeuroGenetic Optimizer yazılımı ile 31 Aralık 1974 -31 Aralık 1998 dönemini kapsayan altın fiyatındaki değişimleri öngörmeyi amaçlamıştır. Farklı yöntemler arasında altın fiyat hareketi öncülüğünde genetik algoritmalar ile geriye beslemeli yapay sinir ağları kullanılmıştır. Sonuçlar, geçmişteki (36 güne kadar) fiyatların geleceğin altın fiyatlarını şiddetle etkilediğini göstermektedir. Bu durum altın fiyat hareketlerinde kısa vadeli zaman bağımlılığının varlığını teyit etmektedir.

Parisi vd., 2008 yılında yaptıkları çalışmada altın fiyatındaki işaret değişimini tahmin etmek için ileri ve geri beslemeli sinir ağı modellerini analiz etmişlerdir. Sonuçlar, altın fiyatı işaret değişkenliklerini tahmin etmek için dinamik bir çerçeveye sinir ağlarının kullanımını desteklemekte, ağırlıkların periyodik olarak yuvarlanan bir süreçle tekrar hesaplanmaktadır. Sonuçlara ilişkin blok önyüklemeye metodolojisi kullanılarak, ortalama işaret tahmini % 60.68 ile ve yuvarlanan sinir ağı için % 2.82'lik bir standart sapma ile doğrulanmıştır.

Hussein vd., (2011) yapay sinir ağlarına farklı bir yaklaşımda bulunarak altın fiyatlarını radyal temel fonksiyon sinir ağlarını kullanarak tahmin etmeye çalışmışlardır. Uygulanan günlük kapanış fiyatlarına ilişkin altın tahmininde %78'lik başarılı bir öngörü düzeyi yakalandığı tespit edilmiştir.

Farahani ve Mehralian 2013'te yayınladıkları çalışmada altın fiyatını tahmin etmek için Yapay Sinir Ağı (ANN) ve Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi (ANFIS) karşılaştırması sunmuşlardır. Ayrıca, ANN ve ANFIS modelinin ağırlıklı ortalaması olan yeni bir hibrid modeli karşılaştırılmıştır. Ana hedef, Forex piyasasındaki altın fiyatı tahmin etmektir. Bu çalışmada önerilen karşılaştırma kriterleri Ortalama Hata Kareler Karekökü (RMSE), yüzde hata ve Ortalama Eğilim Hatasıdır (MTE). Bulgular altın fiyatı tahminlemede ANN'nin en güçlü model olduğunu göstermiştir.

Benli ve Yıldız (2014) çalışmalarında altının gecikmeli değerlerinden hareketle fiyatının tahmin öngörülmesine ilişkin geleneksel zaman serisi metodlarından basit üstel düzleştirme yöntemi, Holt'un doğrusal trend yöntemi, ARIMA modeli ve yapay sinir ağları incelenerek mukayese edilmiştir. Çalışmada Borsa İstanbul'dan elde edilen aylık ağırlıklı ortalama altın fiyatlarından (\$/ons) yararlanılmıştır. Bulgular, yapay sinir ağları modelinin üstel düzleştirme yöntemi ve Holt'un lineer trend metoduna göre daha başarılı olduğunu gösterse de; ARIMA modelinin öngörü de en başarılı tahmin performansına sahip olduğunu sonucuna ulaştırmıştır.

Kocatepe ve Yıldız (2016) çalışmalarında 2007 ile 2015 yılları arasındaki Türkiye'deki altının gram fiyatının değişim yönünü yapay sinir ağları ile tahmin etmeye çalışmıştır. Çalışmada açıklayıcı vasıflar olarak ham petrol değeri, dolar kuru ve endeksi,



Standard&Poor's 500 endeksi, BIST100 endeksi, Türkiye'de enflasyon, tahvil ve faiz oranları, ABD'de enflasyon, tahvil ve faiz oranları, gümüş ve bakır değerleri ele alınmıştır. Araştırmada, etkilenen vasfın gelecekteki fiyatının öngörüsünün gerçekleştirilmesi adına, açıklayıcı değişkenlerin bir ay önceki değerleri incelenmiştir. Araştırma sonucunda gram altın fiyatındaki değişimin tahmin başarısı oranı %75,24 olarak bulunmuştur.

Yüksel ve Akkoç (2016) çalışmalarında altın değerlerini tahmin etmek maksadıyla, yapay sinir ağları modeli oluşturmuşlardır. Bu amaçla kullanılan açıklayıcı vasıflar; gümüş ve Brent petrol değerleri, ABD doları/ EUR paritesi, EuroNext100 endeksi, Amerika Dow Jones Endeksi, 13 Hafta vadeli ABD bonosu faiz oranı ve ABD TÜFE olmuştur. Analiz sonuçlarına göre, altın fiyatlarının öngörüsünde YSA'nın oldukça olumlu sonuçlar verdiği saptanmıştır. Oluşturulan duyarlılık çözümlemesinin sonuçları incelendiğinde altın fiyatlarını etkileyen en önemli değişkenler gümüş ve petrol fiyatları olduğu saptanmıştır.

Çelik ve Başarır (2017), RapidMiner yazılımından yararlanarak YSA modeli ile 4 Ocak 2010 ile 14 Aralık 2015 dönemleri içerisinde altın, gümüş, platin, paladyum, 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 Avro/Dolar serilerinin fiyatlarının öngörülmesini amaçlamışlardır. Yapay sinir ağlarını ele almak adına beş farklı performans kriteri kullanılmıştır. 2015 senesinin dördüncü çeyreğindeki veriler öngörü ve doğrulama üzerine kullanılmıştır. Bulgular, piyasa öngörülerine hata oranlarının kabul edilebilir düzeyde olduğunu belirtmiştir.


YAPAY SİNİR AĞLARI (YSA)

Yapay sinir ağları insan beyninin sinir yapısının simülasyonu, cebirsel biçimde kodlanması uğraşlarının neticesi üzerine türemiştir (Yurtoğlu, 2005: 32). İnsan beyninin sinir sisteminin tanınan yapıları ve görevleri yapay sinir ağlarında matematiksel kodlarla, biyolojik sinir yapısındaki karşılıklarının fonksiyonlarını ortaya koymak adına modellenmiştir. İnsan beyninin aşağı yukarı 10^{11} adet nöron adı verilen hesap öğelerini içerdiği ve bu nöronlar içerisinde 10^{15} bağ kurulduğu bilinmektedir (Kantardzic, 2003: 63).

Şekil I'de temel bir yapay sinir ağı nöronunun (X_1, X_2, \dots, X_n) girdileri ve bu girdilere karşı düşen (W_1, W_2, \dots, W_n) ağırlıklarının sunulmaktadır. Girdiler hazır hale getirilmeden evvel ağırlıklarla çarpılarak toplanır.

$$v = X_1.W_1 + X_2.W_2 + X_n.W_n (1)$$


Elde edilen işaret (v) aktivasyon işlevine aktarılır ve çıktıya (y) ulaşılır. Ağırlık değerleri, işlenen yapay sinir ağı sistemi adına eğitim sürecinde tekrarlanır (Ramaswamy, 1997: 43).



Şekil 1. Yapay Sinir Ağı Modeli (Aydın, 2005: 74)

Yapay sinir ağlarına özgü olağan bir sınıflandırma metodu mevcut değildir. Nöronların bağlanma biçimlerine, yönetilen eğitim algoritmasına, dönem gecikmesine ve elde edilen verinin türüne bağlı olarak göre farklı sınıflandırmalar oluşturulabilir (Kim, 2003: 38). Nöronların bağlanma şekillerine bağlı olarak ileri beslemeli ve geri beslemeli yapay sinir ağları elde edilir (Slaughter, 2003: 45).


Şekil 2’de fiziki sistemi sunulan ileri beslemeli yapay sinir ağlarında nöronlar katmanlar biçiminde oluşturulur ve her bir katmandaki nöronların çıkışları bir sonraki katmana ağırlıklar üstünden girdişeklinde sunulur. Özdeş katmandaki nöronlar içerisinde ya da bir önceki katmana bağ kısacası geri besleme devresi bulunmamaktadır. Girdi katmanı, dış kaynaklardan elde ettiği verileri herhangi bir farklılık oluşturmadan gizli katmandaki nöronlara gönderir. Bilgi orta katmanlarda ve çıktı katmanında çalıştırılarak ağ çıktısı oluşturulur. Bu araştırmada da ileri beslemeli ağ modeline dayalı yapay sinir ağı modeli kullanılmıştır.





Şekil 2. İleri Beslemeli Ağ Modeli (Web, 2006: 14, 14.11.2017)

Şekil 3'te fiziksel sistemi gösterilen geri beslemeli ağlarda minimum tek adet geri besleme devresi mevcuttur. Geri beslemenin oluşturulma düzeni şekilde gösterilmiştir. Geri besleme, aynı katmandaki hücreler (girdi katmanı, gizli Katman, çıktı Katmanı) içerisinde gerçekleşebileceği üzere değişik katmanlardaki nöronlar içerisinde de meydana gelebilir. Geri beslemenin oluşum biçimi üzerinde değişik sistem ve davranımda geri beslemeli yapay sinir ağı sistemleri hazırlanabilir.



Şekil 3. Geri Beslemeli Ağ Modeli (Web, 2006: 15, 14.11.2017)

Yapay sinir ağlarının başarımları değişik parametreler adına ciddi biçimde farklılık gösterir. Bundan dolayı, kurulan modelin gücü oluşturulan ağ sistemi ölçüsünde bu ağ adına belirlenecek öğrenme katsayısı, gizli katman ile nöron sayısını içeren parametrelere de bağlıdır. Gizli katmanlar geri besleme algoritmasının kaynağını meydana getirir ve yapay sinir ağlarının başarısını hazırlayan kısımdır. Gizli katmanlar yüksek düzeyde karakteristiklerin belirlenmesinde ve yapay sinir ağının sürdürülebilir kimliğini elde etmesinde ciddi bir öneme sahiptir (Iskandar, 2005: 32).

Yapay sinir ağında bulunması zorunlu olan gizli nöron adedinin belirlenmesi için farklı formüller geliştirilmiştir. Bir yapay sinir ağı sistemini $InHmOp$ şeklinde ifade edersek,

I: Girdi Katmanı

H: Gizli Katman

O: Çıktı Katmanı



n, m, p: Nöron Sayıları

Bu ağdaki toplam parametre sayısı $(m \times n) + (m \times p)$ şeklinde elde edilir (Kim 2003:56).

Öğrenme katsayısı (ϵ), genellikle tüm yapay sinir ağlarında yararlanılan, 0 ile 1 arasında değeri olan bir katsayıdır. Öğrenme katsayısı sistemin eğitim ivmesinin gözden geçirir. Öğrenme katsayısının büyük seçilmesi ağın istenen değere yakınsaması için geçen süreyi azaltır ancak ağın yetersiz iki çözüm arasında salınma girmesine neden olabilir. Öğrenme katsayısının küçük seçilmesi ise ağın yakınsama zamanını uzatır (Larose, 2005:140).

VERİ VE YÖNTEM

YSA ile türetilen modellerde 03.01.2005– 31.10.2017 dönemleri kapsamında bulunan 2784 günlük veri incelenmiştir. Tablo 1’de oluşturulan modellerde yer alan değişkenler ve elde edildikleri kaynaklar belirtilmiştir.

Tablo 1. Araştırmada Kullanılan Değişkenler ve Kaynakları

	Değişkenler	Birim	Veri Türü	Simge	Kaynak
Y	Altın	\$/ons	Günlük	A	www.evds.tcmb.gov.tr
X1	Petrol	\$/varil	Günlük	BP	www.economagic.com
X2	Dow Jones Endeksi (log)	\$	Günlük	LDJI	Yahoo Finance
X3	Gümüş	\$/ons	Günlük	G	www.kitco.com
X4	Parite	€/€	Günlük	EUR/USD	www.federalreserve.gov
X5	EuroNext Endeksi (log)	€	Günlük	LN100	Yahoo Finance

Tablo 2’de ise açıklayıcı vasıflara ilişkin bazı tanımlayıcı istatistik verilerine yer verilmiştir.

Tablo 2. Bağımsız Değişkenlerin Tanımlayıcı İstatistikleri

Simge	Minimum	Maksimum	Ortalama	Standart Sapma
BP	10,89	140,85	81,31	26,73
LDJI	7,09	10,38	10,14	0,13
G	6,40	20,24	17,12	2,37
EUR/USD	1,04	1,60	1,30	0,12
LN100	8,00	9,00	8,49	0,28

YSA modelinin oluşturulmasında R Studio yazılımı kullanılmıştır. 2784 günlük veri; %70’lik (1948 adet) kısmı eğitim, %15’lik (418 adet) kısmı geçerlilik, diğer %15’lik (418 adet) kısmı da test adına incelenmek için yazılım aracılığıyla rassal olarak ayrıştırılmıştır. Yazın taramasında, YSA’nın gizli katmanda bulunacak nöron adedinin tespitine yönelik kabul edilen kesin formülasyon olmadığından ötürü, oluşturulan veri yapısı 5 açıklayıcı değişken ile öngörülen gizli katmanda sırasıyla 5, 10, 15, 20, 25 nöron dahil edilerek YSA modeli adın incelenmiş ve optimum netice elde edilmeye çalışılmıştır. Öğrenme algoritması için Levenberg – Marquardt algoritması seçilmiş ve öğrenme katsayısı 0.5 alınmıştır.



BULGULAR

Altın fiyatlarına ilişkin tahmine yönelik çalıştırılan modellerin başarısı farklı ölçütler (R^2 , RMSE, MAE ve MAPE) göz önünde bulundurularak kontrol edilmiştir. YSA'nın başarısını değerlendirmek adına YSA modeli altın fiyatları ile gerçek sonuçların R^2 , RMSE (Ortalama Hata Kareleri Karekökü), MAE (Ortalama Mutlak Hata) ve MAPE (Ortalama Mutlak Yüzde Hata) değerleri hesaplanmıştır.

$$R^2 = 1 - \frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^N (Y_i - \bar{Y})^2} \quad (2)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (Y_i - \hat{Y}_i)^2}{N}} \quad (3)$$

$$MAE = \frac{\sum_{i=1}^N |Y_i - \hat{Y}_i|}{N} \quad (4) \quad MAPE = \frac{\sum_{i=1}^N \frac{|Y_i - \hat{Y}_i|}{Y_i}}{N} \cdot 100 \quad (5)$$

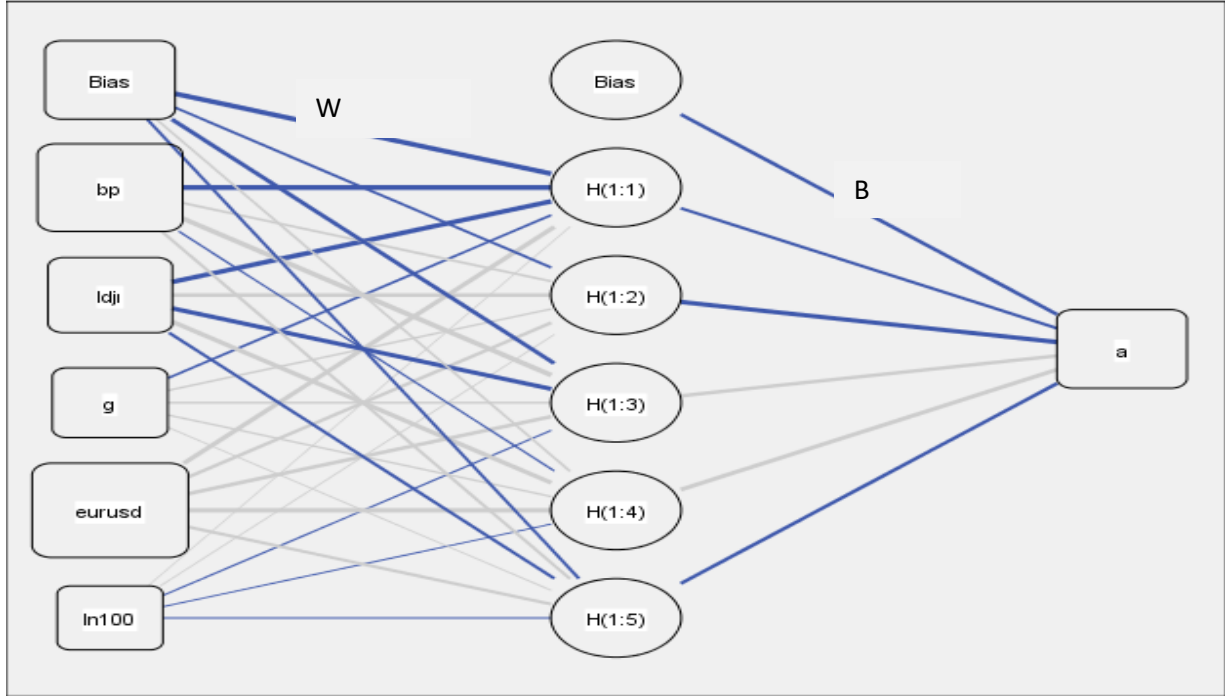
Burada;

Y_i = Gerçek Değer

\hat{Y}_i = Öngörülen Değer

\bar{Y} = Gerçek Değerlerin Aritmetik Ortalaması

N = Gözlem Değeri



Şekil 4. Oluşturulan Yapay Sinir Ağı

Şekil 4’te çalışma için oluşturulan yapay sinir ağı modeli verilmiştir. Burada bağımsız değişkenler girdi katmanını; H(1:1), H(1:2), H(1:3), H(1:4), H(1:5) gizli katmanları; W ve B çıkış katmanı ağırlık ve sapmalarını (biasları); bağımlı değişken ise çıkış katmanını ifade etmektedir. Öğrenme katsayısı 0,5 alınmıştır.

Tablo 3’te yer alan YSA modelinin eğitim, geçerlilik ve test sonuçlarında elde edilen korelasyon (r) değerleri aşağıdaki gibidir.

Tablo 3. Gizli Katmandaki Nöron Sayıları ve Bu Katmanlarda Eğitim, Geçerlilik ve Test Seti İçin r Değerleri

Nöron Sayısı	Eğitim Seti	Geçerlilik Seti	Test Seti
5N	0,7942	0,7963	0,7989
10N	0,7986	0,7991	0,7996
15N	0,8044	0,8087	0,8092
20N	0,8132	0,8159	0,8176
25N	0,8377	0,8384	0,8392

Eğitim ve geçerlilik seti adına kesilen verilerin korelasyon değerleri incelendiğinde, gizli katman sayısının yükselmesiyle öğrenme başarısı da artış göstermiş böylece test adına kesilen veri seti de daha olumlu neticeler vermiştir.

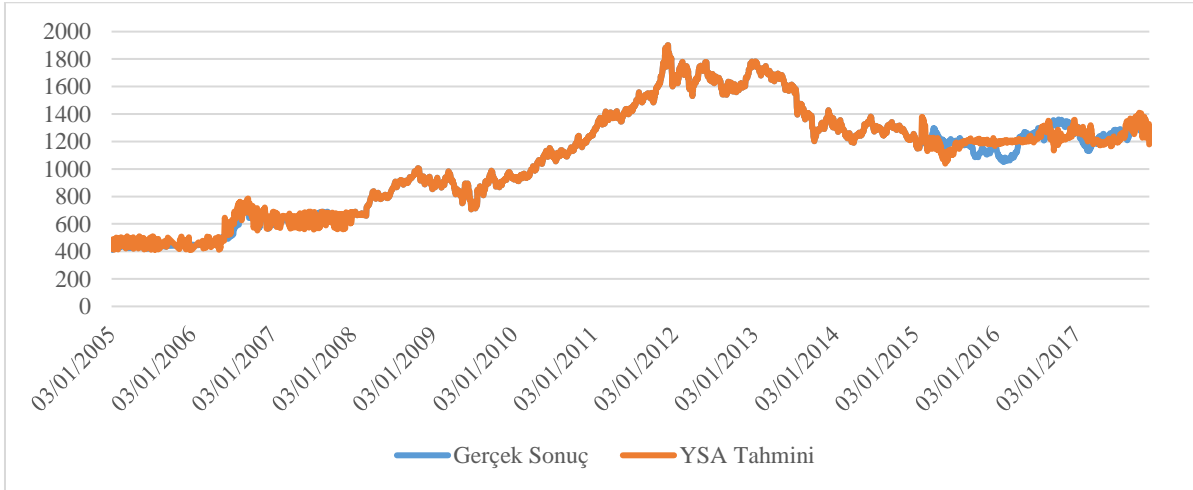


YSA modeline göre tahmin edilen altının günlük kapanış değerleri ile gerçek neticelerin R^2 , RMSE, MAE ve MAPE değerleri bulunarak sonuçlar Tablo 4’te gösterilmiştir.

Tablo 4. Gizli Katman Sayıları ve Elde Edilen R^2 , RMSE, MAE ve MAPE(%) Değerleri

Nöron Sayısı	R^2	RMSE	MAE	MAPE(%)
5N	0,7178	49,6559	38,7532	6,4365
10N	0,7665	48,8735	37,6936	6,2189
15N	0,7845	47,3682	36,8765	5,8504
20N	0,7960	46,9047	35,8064	5,5682
25N	0,8265	45,8066	34,6753	5,4308

Meydana getirilen veri yapısı YSA’da 5 ile 25 nöronla eğitilip, test edilmiştir. Tablodan da anlaşılacağı gibi optimum sonuçlar 25 nöronla oluşturulan modelden sağlanmıştır. R^2 değeri nöron sayısı arttıkça artmış, RMSE, MAE ve MAPE değerleri nöron sayısı arttıkça azalmıştır. Şekil 3’te YSA modelinin altın fiyatı için ürettiği değerlerin gerçek değerlerle ilişkisi verilmiştir.



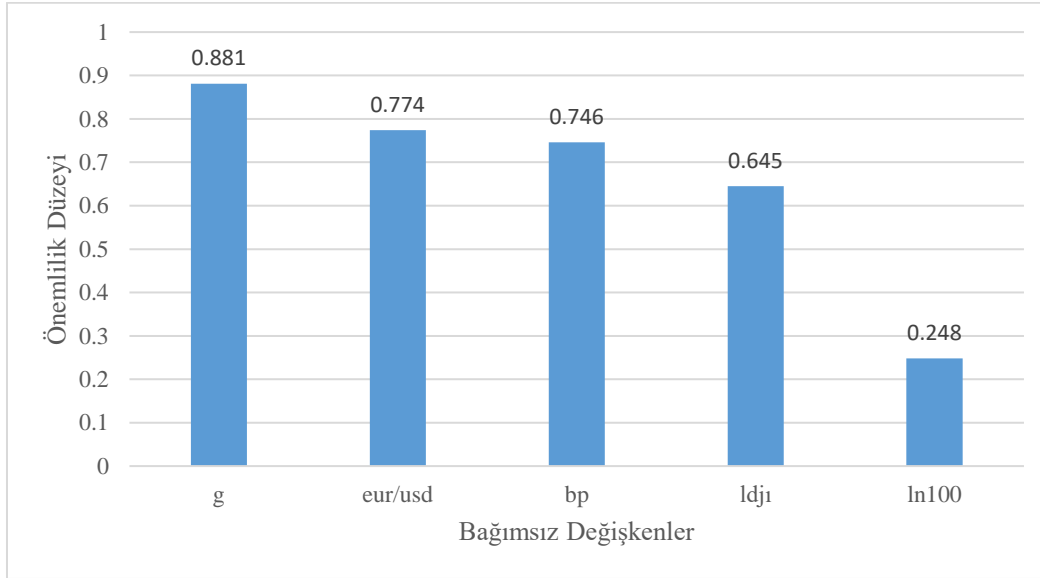
Şekil 3. Altın Fiyatlarının Gerçek Değeri ve YSA Tahmin Değerleri

Şekil 3’e göre altın için üretilen YSA değerlerinin gerçek değerlere çok yakın olduğu görülebilmektedir. Ağın başarı oranı %81,43 olarak tespit edilmiştir.

Bu aşamadan sonra son olarak altın fiyatları tahmininde bağımsız değişkenlerin önem düzeyleri dikkate alınmıştır. Geçerlilik analizi açıklayıcı vasıflar arasında altın değerlerine maksimum etkide bulunan vasfın (r_{ij}) derecesini belirlemek adına geliştirilmiştir. r_{ij}



katsayısının yüksekliği açıklayıcı vasıfların altın değerlerine olan etkisini arttırmaktadır. Analize ilişkin bulgulara Şekil 4'te verilmiştir.



Şekil 4. Bağımsız Değişkenlerin Geçerlilik Analizi

Şekil 4'e göre gümüşün geçerlilik derecesi katsayısı $r_g = 0,881$ olarak elde edilmiştir. Diğer açıklayıcı vasıflarına ise r katsayısı; parite için $r_{eur/usd} = 0,774$, petrol için $r_{bp} = 0,746$, Dow Jones Endeksi adını $r_{ldji} = 0,645$, ve Euronext 100 endeksi adına $r_{ln100} = 0,248$ olarak hesaplanmıştır. Bağımsız değişkenlerin altın fiyatlarını ne derece etkilediği bu şekilde ortaya koyulmuştur. Altının önemli derecede ikamesi olan gümüş altın fiyatları tahmininde etkisi en büyük olan bağımsız değişken olarak tespit edilmiştir. Altın fiyatları sırasıyla EUR/USD paritesinden, Brent petrolünden yüksek oranda, Dow Jones Endeksinden orta oranda etkilenmiştir. Euronext 100 Endeksi ise altın fiyatı tahminlerinde en zayıf etkisi bulunan değişken olarak belirlenmiştir.

SONUÇ

Araştırmada altın fiyatlarını tahmin etmek amacıyla yapay sinir ağlarından yararlanılmıştır. YSA ile kestirim; eğitim, geçerlilik ve test aşamalarını içerdiğinden ötürü ötekili yöntemlere nazaran çok sayıda veriye gereksinimi olmaktadır. Çok sayıda veri ile de kestirimi yapılması beklenen vasıf adına optimum neticeler kazanılması sağlanacaktır.

Çalışma kapsamında altın değerlerinin öngörüsünde Brent petrol, gümüş, EUR/USD paritesi, Dow Jones Endeksi ve Euronext 100 endeksi (logaritması alınmış seriler) bağımsız değişken olarak kullanılmıştır. Tahmin edilen seri olan altının kapanış fiyatı (\$/ons) modelin çıktısı iken; bağımsız değişkenler YSA modelinin girdisi konumunda yer almıştır. YSA modelinden elde edilen sonuca göre ağın başarı oranı %81,43 olarak tespit edilmiştir. Bu sonuç modelin hem iyi eğitildiğini, hem de bağımsız değişkenlerin seçilmesindeki isabetin yüksek olduğunu göstermektedir. Geçerlilik çözümlemesi incelendiğinde altın değerleri en fazla gümüş



fiyatından, akabinde sırasıyla EUR/USD paritesi, Brent petrol, Dow Jones Endeksi ve Euronext 100 Endeksi değerlerinden etkilenmektedir.

Bu çalışma sonraki çalışmalar açısından diğer ekonomik değişkenlerin tahmin edilmesinde yapay sinir ağları ve makine öğrenme programları uygulanarak modeller işlenebilir. YSA ile işlenebilen modellerin başarıları, zaman serisi analiz teknikleri ile mukayese edilebilir.

KAYNAKÇA

- Aksu, E. (2008) "Altın piyasasında fiyat oluşumu", Atatürk Üniversitesi Sosyal Bilimler Enstitüsü İktisat Yüksek Lisans Tezi, Erzurum.
- Aksoy, M. ve Topçu, N. (2013) "Altın ile hisse senedi ve enflasyon arasındaki ilişki", Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, 27(1), s:59-78.
- Aydın, Ö. (2005) "Yapay Sinir Ağlarını Kullanarak Bir Ses Tanıma Sistemi Geliştirilmesi", Yüksek Lisans Tezi, Bilgisayar Mühendisliği ABD, Trakya Üniversitesi, Edirne, 74s.
- Balı, S. ve Cinel, M.O, (2011) "Altın Fiyatlarının İMKB 100 Endeksi'ne Etkisi ve Bu Etkinin Ölçülmesi", Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi, 25(3-4), s:45-63.
- Benli Y. K. ve Yıldız A. (2014) "Altın fiyatının zaman serisi yöntemleri ve yapay sinir ağları ile öngörüsü. Dumlupınar Üniversitesi Sosyal Bilimler Dergisi, 42. Sayı, 213- 224.
- Cihangir, C. ve Uğurlu, E., (2013) "Yatırım Aracı Olarak Altın: 2004-2012 Dönemi Türkiye Örneğinde Oynaklık İncelemesi", Uluslararası İstanbul Finans Kongresi 2013, Kadir Has Üniversitesi, İstanbul.
- Çelik, U. ve Başarır, Ç. (2017) "The Prediction of Precious Metal Prices via Artificial Neural Network by Using Rapid Miner", The Journal of Operations Research, Statistics, Econometrics and Management Information Systems, 5(1), s:46-54.
- Elmas, B. ve Polat, M. (2014) "Altın Fiyatlarını Etkileyen Talep Yönlü Faktörlerin Tespiti: 1988-2013 Dönemi", Çukurova Üniversitesi İktisadi ve İdari Bilimler Dergisi, 15(1), s:171-187.
- Farahani, M. ve Mehralian, S. (2013) "Comparison between artificial neural network and neuro-fuzzy for gold price prediction", Proceeding of the 13th Iranian Conference on Fuzzy Systems (IFSC, 2013), s: 1-5.
- Ghosh, D., Levin, E. J., Macmillan, P., ve Wright, R. E. (2004) "Gold as an inflation hedge?", Studies in Economics and Finance, 22(1), s: 1-25.
- Hussein, S.F.M, M. B. N. Shah, M. R. A. Jalal, ve S. S. Abdullah (2011) "Gold price prediction using radial basis function neural network," in Proceedings of the 4th International Conference on Modeling, Simulation and Applied Optimization, s:1-11.



- Iskandar, N. F. (2005) “An Artificial Neural Network Approach For Short Term Modeling of Stock Price”, Index, Ph. D. Thesis, Industrial Systems Engineering, University of Regina, Saskatchewan, 85s.
- Kırlıoğlu, H. ve Fidan, M.E, (2006) “Kuyumculuk Sektörümüz, Sorunları ve Çözüm Önerileri”, Muhasebe ve Finansman Dergisi, 29(1), s:40-50.
- Kim, J. Y. (2003) “ANN Wave Prediction Model For Winter Storms and Hurricanes”, Ph. D. Thesis, The School of Marine Science, The College of William and Marry, Virginia, 246s.
- Kocatepe, C.İ. ve Yıldız, O. (2016) “Ekonomik Endeksler Kullanılarak Türkiye’deki Altın Fiyatındaki Değişim Yönünün Yapay Sinir Ağları İle Tahmini”, Düzce Üniversitesi Bilim ve Teknoloji Dergisi, 4, s: 926-934.
- Larose, D.T . (2005) “Discovering Knowledge in Data: An Introduction to Data Mining”, John Wiley & Sons, Inc., Hoboken, 215s.
- Mirmirani, S. ve Li, H.C. (2004) “Gold Price, Neural Networks and Genetic Algorithm”, Computational Economics, 23(2), s:193-200.
- Parisi, A., Parisi, F. ve Díaz, D. (2008) “Forecasting gold price changes: Rolling and recursive neural network models”, Journal of Multinational Financial Management, 18(5), s:477-487.
- Ramaswamy, S. (1997) Decision Support System Using Neural Networks, M.S. Thesis, Computer Science, University of Nevada, Nevada, 79s.
- Ranson, D. (2005a) “Why gold, not oil, is the superior predictor of inflation”, London: World Gold Council.
- Ranson, D. (2005b) “Inflation protection: Why gold works better than linkers”, London: World Gold Council.
- Öztürk, F. ve Açıkalın, S. (2008) “Is gold a hedge against Turkish lira?”, South East European Journal of Economics and Business, 3(1), s:35-40.
- Slaughter, G. E. F. (2003) “Artificial Neural Network For Temporal Impedance Recognition of Neurotoxins”, M.S. Thesis, The School of Engineering, Virginia Commonwealth University, Virginia, 115s.
- Toraman, C., Başarır, Ç., Bayramoğlu, M. F. (2011) “Altın fiyatlarını etkileyen faktörlerin tespiti üzerine: Mgarch modeli ile bir inceleme”, Uluslararası Alanya İşletme Fakültesi Dergisi, 3(1), s:1-20.
- Vural, M. G. (2003) “Altın piyasası ve altın fiyatlarını etkileyen faktörler”, Ankara: Türkiye Cumhuriyeti Merkez Bankası, Piyasalar Genel Müdürlüğü.



AKADEMİKBAKIŞ DERGİSİ

Sayı: 72 Mart - Nisan 2019

Uluslararası Hakemli Sosyal Bilimler E-Dergisi

ISSN: 1694-528X İktisat ve Girişimcilik Üniversitesi, Türk
Dünyası Kırgız – Türk Sosyal Bilimler Enstitüsü, Celalabat –
KIRGIZİSTAN <http://www.akademikbakis.org>



Yüksel, R. ve Akkoç, S. (2016) “Altın Fiyatlarının Yapay Sinir Ağları ile Tahmini ve Bir Uygulama”, Doğu Üniversitesi Dergisi, 17(1), s:39- 50.

İNTERNET KAYNAKLARI

Dünya Bülteni (2008) Erişim adresi: <http://www.dunyabulteni.net/index.php?aType=haberArchive&ArticleID=36654>, (Erişim Tarihi: 12.10.2017).

Web (2006) Yesevi Net, Ders Notları, www.yesevi.net/muh/ysa.doc, (Erişim Tarihi: 14.11.2017).