



Altın/ Dolar Paritesinin Farklı Yapay Sinir Ağları Öğrenme Algoritmaları Kullanarak Bir Sonraki Kur Tahmini

Güneş HARMAN^{1*}

¹Yalova Üniversitesi, Mühendislik Fakülte, Bilgisayar Müh. Bölüm, Yalova, TÜRKİYE

Özet

Hızla gelişmekte olan teknolojik araçlar, karmaşık hesaplama yöntemlerinin büyük çaplı verilere uygulanabilmesine imkân tanımıştır. Böylece birçok alanda, insanın bilgi ve tecrübesinin yetişemediği sürelerde birtakım sonuçlar elde edilmekte ve bu sonuçlara bağlı karar mekanizmaları oluşturulmaktadır. Bu alanlardan biri de sıklıkla gündemde kalan altın ve dolar paritesidir. Ekonomiye ve sosyal yaşantıya olan etkisi, altın ve dolar paritesine yönelik finansal öngörülerle karar vermeyi oldukça önemli hale getirmiştir. Bu kapsamda Geri Yayılımlı Çok Katmanlı Yapay Sinir Ağlarıyla farklı öğrenme teknikleri kullanılarak, altın ve dolar paritesinin sonraki kur tahmini yapıldı. Öznitelik olarak; seçilen bir başlangıç zamanından itibaren bilinen son tarihe kadar kaydedilmiş olan altın fiyatları (XAU/USD), Ham petrol fiyatları, Hisse senedi gelirleri (NYSE 200 borsası), Tahvil faizi değerleri ve son olarak Gümüş Fiyatları parametre olarak kullanıldı. Muhtelif yapı ve özelliklerde çok katmanlı yapay sinir ağları eğitilerek regresyon analizi gerçekleştirildi. Bu analiz için üç farklı algoritmanın - Levenberg-Marquardt, Bayesian Regularization ve One-step secant algoritması- performansı; farklı gizli katman sayıları, bu katmanlarda kullanılan farklı nöron sayıları ve farklı aktivasyon fonksiyonları kullanılarak karşılaştırılmıştır. Performans metriği olarak belirleme katsayısı (R Kare) ortalama mutlak hata (MAE), mutlak ortalama yüzde hata (MAPE) ve ortalama hata karekökü (RMSE) kullanıldı. Çalışmadaki en iyi sonuç, 2 gizli katmanlı her bir katmanda 3 nöron bulunan ve Levenberg Marquardt eğitim algoritması kullanılarak elde edildi. (R²: 0.97, MAPE : 0.005, MAE:5.88, RMSE:7.23)

Makale Bilgisi

Başvuru:
20/06/2022
Kabul:
05/09/2022

Anahtar Kelimeler: Yapay Zekâ, Yapay Sinir Ağları, Geri Yayılım Algoritması, Regresyon, Levenberg-Marquardt, Bayesian Regularization, One-step secant, Altın- Dolar Paritesi.

Using Different Neural Networks Learning Algorithms Next Rate Prediction of Gold/Dollar Parity

Abstract

Rapidly developing technological tools, especially large-scale data have made it possible to apply complex computational methods. Thus, in many areas, some results are obtained when human knowledge and experience cannot reach, and decision mechanisms are formed based on these results. One of these areas is the gold and dollar parity, which is often on the agenda. Its effect on the economy and social life has made it very important to make decisions with financial forecasts for gold and dollar parity. Its effect on the economy and social life has made it very important to make decisions with financial forecasts for gold and dollar parity. In this context, the next exchange rate prediction of gold and dollar parity was made by using different learning techniques with Backpropagation Multilayer Artificial Neural Networks. As

an attribute, gold prices (XAU/USD), Crude oil prices, Equity earnings (NYSE 200 exchange), Bond interest values and finally Silver Prices, recorded from a selected start time to the known deadline, were used as parameters. Regression analysis was performed by training multilayer artificial neural networks with various structures and features. The performance of three different algorithms -Levenberg-Marquardt, Bayesian Regularization and One-step secant algorithm- for this analysis; Different hidden layer numbers are compared using different neuron numbers and different activation functions used in these layers. The coefficient of determination (R Squared), mean absolute error (MAE), absolute mean percent error (MAPE) and root mean square error (RMSE) were used as performance metrics. The best result in the study was obtained by using the Levenberg Marquardt training algorithm with 3 neurons in each layer with 2 hidden layers. (R2: 0.97, MAPE: 0.005, MAE: 5.88, RMSE: 7.23)

Keywords: : Artificial Intelligent, Artificial Neural Network, Back Propagation Algorithms, Regression, Levenberg-Marquardt, Bayesian Regularization, One-step secant Gold/ Dollar Parity.

1 Giriş

Tarihten bu yana süre gelen ve günümüzde de değerini yitirmeyen altın; başta ziynet olmak üzere, birikim ve değişim aracı olarak kullanılmıştır [1-2]. Fiziksel ve kimyasal nitelikleri göz önüne alındığında doğada bulunan ve işlenebilen diğer madenlere göre üstünlüklerinden dolayı geçmişten günümüze insanların ilgisini çekmiş, uğruna sosyal zararları büyük çapta olan mücadelelerin verilmesine neden olmuştur. Bugün hala takı olarak ve külçe halinde rezerve edilmesi şeklinde özellikle finansal piyasalarda önemini korumaktadır. Yine devletler açısından ekonomik gücün göstergesi olmayı sürdürmektedir [3-4]. Genel itibariyle tüm dünya ülkeleri ve bunların merkez bankaları varlığını sürdüren bireyler ve kurumlar için en iyi riskten korunma aracı olarak değerlendirilmekte ve kullanılmaktadır. Aynı zamanda kıymetini yitirmemesi nedeniyle en çok tercih edilen yatırım araçlarından birisidir [5].

Bununla beraber kıyaslandığı değişim ölçütü referans alındığında hemen her maddede olduğu gibi altının değeri arz ve talep durumuna göre kısa vadede artıp azalabilmektedir. Yatırım hazırlığı içerisinde olan kişi ve kurumların talep öncesinde karar verme aşamasında baktığı en önemli nitelik altının "son an" ve ondan önceki "geçmiş" değerleridir. Bu bilgiler göz önüne alındığında çalışma kapsamında kullanılan veriler yaygın olarak XAU/USD şekilde ifade edilen paritenin son 5 yılda kaydettiği değişim verileri kullanılarak yapılmıştır.

Küresel düzeyde önemi vurgulanan bu madenin değişkenliğinden her insan; bazen en çok fayda sağlayarak, bazen de en az zarar görerek yaşamına devam etmek ister. Kişi ve kurumların altının değerindeki değişimin ne yönde olabileceğinin

tahmini ile karar verme durumunda kalmaları özellikle uzun yıllar sonucu elde edilen ekonomik tecrübelerden yararlanılarak elde edilen, çeşitli yöntemlerle daha doğru ve yerinde kararlara ulaşabilmeleri için çabalamada bulunmaya sevk etmiştir. Bu çalışmada bu nitelikte olup çok katmanlı yapay sinir ağı kullanılarak, Altının bir Ons 'unun ABD doları cinsinden değerinin bir sonraki kur tahmini yapılmıştır [6-8].

Bu kapsamda, altının incelenecek para birimi açısından değerinin değişimini nelerin etkilediğinin belirlenmesi gerekmektedir. Bu değişkenler özellikler olarak ifade edilmektedir. Altın dolar paritesini etkileyen nitelikler belirlenirken incelenen para biriminin ABD doları olması ve neredeyse tüm dünya piyasalarını etkilemesi itibariyle ve daha doğru sonuçlara ulaşabilmek için, ilgili faktörler de ABD'nin ekonomik verileri dikkate alınarak sürdürülmüştür. Bu niteliklerin bir kısmı günlük olarak, bir kısmı aylık olarak periyodik belirlenmekte ve kayıt altında tutulmaktadır. Veri tutarlılığını sağlamak amacıyla Altın/dolar paritesinin etkilendiği bilinen ancak ay bazında belirlenebilen öz nitelikler kullanılmamış olup, ilgili parametrenin en çok etkilendiği tespit edilen özelliklerden;

1. Seçilen bir başlangıç zamanından itibaren bilinen son tarihe kadar kaydedilmiş olan altın fiyatları, (XAU/USD)
2. Ham petrol fiyatları
3. Hisse senedi gelirleri (NYSE 200 borsası)
4. Tahvil faizi değerleri
5. Gümüş Fiyatları

Olmak üzere günlük değişimleri kaydedilen 5 adet ana nitelik /özellik kullanılmıştır.

Sayısal olarak ifade edilmeyen ve beklenmedik bir şekilde cereyan edebilen; politik, sosyal ve ekonomik belirsizlikler, kargaşalar veya savaşlar gibi genel itibariyle ani etkileri olan değişkenler, soyut olmaları nedeniyle çalışma dışında kalmıştır [5] [9-11].

Özellikle son yıllarda istatistiksel ve hesaplamalı zekâ temellerine dayanan finansal zaman serisi tahminlerinde makine öğrenmesi (MÖ) yöntemlerinden faydalanılmaktadır. Bir sonraki kur tahmini kapsamında şimdiye kadar yapılmış olan çalışmalar incelendiğinde ana nitelik olarak altın, dolar, petrol ve vb. farklı ana değerlerin kriter olarak kullanıldığı görülmektedir. Yapılan çalışmalardan biri olan [12] altın fiyatlarının tahmininde Çok Katmanlı Yapay Sinir Ağları (Multi Layer Perceptron -MLP) kullanmıştır. Oluşturulan modelin değerleri olarak; Brent Petrol fiyatı, VIX (Volatility Index) endeksi, Dow Jones endeksi ve ABD doları endeksi kullanılmıştır. Çalışma %98,44 doğruluk oranıyla başarılı bir sonuç vermiştir. Altın fiyatların günlük getirisinin tahmini için yapılan bir diğer çalışmada [13] Markov Zincirleri Modelleri (Markov Chain Model) ve Yapay Sinir Ağları (Artificial Neural Network - ANN) yapıları birlikte kullanılmıştır. Oluşturulan modelin girdi değerleri Türkiye'ye ait 2 Ocak 2008 ile 28 Şubat 2017 tarihleri arasındaki günlük altın/ons kapanış fiyatları serisi olarak belirlenmiş, sonuç olarak %70 doğruluk oranı elde edilmiştir. Yapılan diğer bir çalışma da [14] altın tahmini için ANN kullanılmış olup girdi olarak Gümüş fiyatları, Brent Petrol fiyatları, ABD doları/EUR paritesi, EuroNext100 endeksi, Amerika Dow Jones Endeksi, 13 Hafta vadeli ABD bonusu faiz oranı ve ABD TÜFE endeksi kullanılmıştır. Diğer bir çalışmada [15] Sinirsel Bulanık Denetim Sistemi ve ANN kullanılmıştır. Çalışmada USD Endeksi (ABD dolarının Kanada doları karşısındaki performans ölçütü), enflasyon oranı (ABD enflasyon oranları), petrol fiyatı (Batı Teksas Ham Petrol Fiyatları), faiz oranı (Amerika Birleşik Devletleri faiz oranları), hisse senedi piyasa endeksi (Dow Jones Industrial Average), gümüş fiyatı ve dünya altın üretim verileri girdi parametresi olarak kullanılmıştır. Diğer bir çalışmada [16] altın fiyatların tahmin edilmesi için Tek Gizli Katmanlı ileri beslemeyi yapay sinir ağı modeli kullanılmıştır Altın fiyatları, gümüş fiyatları, Ham petrol fiyatları, Standard & Poor'un 500 borsa endeksi (S & P 500) ve döviz kuru ile ilgili geçmiş veriler girdi olarak kullanılmış ve %93,82 doğruluk

oranı vermiştir. Döviz kuru tahmininde ANN ve Regresyon analizini karşılaştırılmasının yapıldığı çalışmada [17] girdi değeri olarak USD/TRY, USD/ONS, TRY/GR, TÜFE, BİST, M3 para arzı, ihracatın ithalatı karşılama oranı, ihracat değişim oranı, dış ticaret dengesi, portföy yatırımları, net hata ve noksan, doğrudan yatırımlar net göstergelerinin kullanıldığı 13 nitelik kullanılmıştır. ANN (MSE- 0.000234246) kullanılarak oluşturulan tahmin performansı regresyon analizine (MSE-0.000490844) göre daha iyi sonuç vermiştir. Döviz kuru tahmini için yapılan bir diğer çalışma olan [18] ANN ve Yapısal Model karşılaştırılması yapılmıştır. Girdi değerleri olarak yerli ve yabancı parasal ekonomi verileri kullanılmıştır. Tahmin performans karşılaştırılmasında ANN modelinin, yapısal modele göre daha iyi sonuçlar vermiştir. Kur tahmininde Yapay Sinir Ağları ve istatistiksel yöntemlerin karşılaştırıldığı bir diğer çalışmada [19] girdi parametresi olarak günlük bazda Euro/TL verileri kullanılmış olup performans değerlerinin karşılaştırılmasında MAE kullanılmış olup en iyi sonucu ANN (0.0198) vermiştir.

Şimdiye kadar yapılmış olan çalışmalar incelendiğinde kur tahmini için çok farklı parametreler ve yöntemler kullanılmıştır. Yapılmış olan bu çalışma kapsamında verilen değişkenlerin, öznel olarak kullanılmasıyla Çok Katmanlı Yapay Sinir Ağı eğitilerek Regresyon analizi gerçekleştirilmiş, böylece altın/dolar paritesinin sonraki kur tahmini yapılması incelenmiştir.

Bu çalışmanın en önemli amacı; Levenberg-Marquardt, Bayesian Regularization ve One-step secant gibi farklı öğrenme algoritma performansları; farklı gizli katman sayıları, bu katmanlarda kullanılan farklı nöron sayıları ve farklı aktivasyon fonksiyonları kullanılarak karşılaştırılmıştır. Performans metriği olarak belirleme katsayısı (R Kare) ortalama mutlak hata (MAE), mutlak ortalama yüzde hata (MAPE) ve ortalama hata karekökü (RMSE) kullanıldı. Çalışmadaki en iyi sonuç, Levenberg Marquardt eğitim algoritması kullanılarak elde edildi.

Çalışmanın ilerleyen bölümleri şu şekilde devam etmektedir. Bölüm 2'de çalışma kapsamında kullanılan veri setine ait her bir nitelik hakkında kapsamlı bilgi verilmiştir. Bölüm 3 Çok Katmanlı Yapay Sinir Ağları modelinin oluşturulmasıyla ilgili bilgi içermektedir. Bölüm 4 çalışmada kullanılan veri setinde yapılan ön-işleme işlemleri detaylı olarak anlatılmaktadır. Bölüm 5 oluşturulan modelin model performans değerlendirmesinden oluşmaktadır.

Bölüm 6 Deneyler ve Tartışma ve son olarak Bölüm 7 Sonuçlar kısmı bulunmaktadır.

2 Veri Seti

Çalışmada kullanılan niteliklerin, finansal açıdan araştırılan pariteye etkisinin belirlenmesi amacıyla incelenmesi bölümün devamında açıklanmıştır.

2.1 XAU/USD geçmiş zaman değerleri

Bilindiği üzere diğer tüm değişim araçlarında olduğu gibi altının da piyasa değerinin temelinde arz talep söz konusudur. Arza göre talep fazlalığı değer kazanma ve fiyat artışı olarak; buna karşın talebin az olması ise değer düşüşü olarak yansımaktadır. Yatırım hazırlığı içerisinde olan kişi ve kurumların talep öncesinde karar verme aşamasında ilk olarak baktığı en önemli nitelik altının son anı ve ondan önceki geçmiş değerleridir. Bu hem reel olarak gözlemlenen hem de bundan yararlanarak otoregresif modelleme gibi matematiksel çalışmalar sonucu etki oranını yüksek olduğu saptanmış bir nitelik olduğunu ortaya konulmuştur. Bu nedenle eğitilecek yapay sinir ağına hata oranı düşük tahminlerde bulunması amacıyla bu özelliğe ait veriler de giriş olarak ele alınmıştır. Her bir tahmin için önceki günün en yüksek ve en düşük değerlerinin ortalaması alındıktan sonra son durum açısından düşüş veya yükseliş eğilimin bilgisini de barındırması amacıyla, kapanış değeri ile ağırlıklı ortalama işlemine tabi tutulmuştur. XAU/USD geçmiş zaman değerlerine ait belli zaman aralığında kullanılan veri Şekil 1’de gösterilmiştir.

XAU/USD Geçmiş Verileri

Zaman: Haftalık Verileri İndir 01/01/2015 - 30/11/2020

Tarih :	Şimdi :	Açılış :	Yüksek :	Düşük :	Fark % :
29.11.2020	1.837,61	1.789,05	1.848,26	1.764,69	2,77%
22.11.2020	1.788,13	1.869,84	1.876,72	1.773,93	-4,40%
15.11.2020	1.870,49	1.888,74	1.899,35	1.852,48	-0,93%
08.11.2020	1.888,04	1.954,65	1.965,92	1.850,36	-3,25%
01.11.2020	1.951,51	1.878,59	1.960,77	1.873,21	3,92%
25.10.2020	1.877,95	1.902,34	1.911,34	1.859,67	-1,20%
18.10.2020	1.900,79	1.899,94	1.931,41	1.894,54	0,10%
11.10.2020	1.898,97	1.930,50	1.933,45	1.882,44	-1,58%
04.10.2020	1.929,43	1.902,24	1.930,83	1.873,05	1,62%

Şekil 1. XAU/USD geçmiş zaman değer verileri.

2.2 Ham Petrol

Teksas petrolü olarak da bilinen Western Texas Intermediate (WTI) petrolü, Batı Teksas'ta çıkarılan ham petrolün genel adıdır. Siyah altın olarak adlandırılan ve kabul edilen ham petrol; ulaşım, enerji, otomobil, ilaç sektörü ve kozmetik alanları başta olmak üzere birçok alanda kullanılmaktadır.

Ekonomik, siyasi ve jeopolitik gelişmeler ham petrol fiyatlarını etkilen en önemli unsurların başında gelmektedir. Ortadoğu'daki jeopolitik risklerin artması ve global ekonomide ortaya çıkan gelişmeler fiyatlarda yüksek oynaklığa sebep olmaktadır. Fiyatları etkileyen diğer etkenler arasında arz talep dengesinde meydana gelen değişiklik veya değişiklikler, petrol rezerv miktarlarında meydana gelen değişiklikler, enerji talepleri, küresel iklim değişiklikleri bulunmaktadır. Küresel ticarete büyük bir hacme sahip olan Ham Petrol, emtia piyasalarının en gözde yatırım araçları içindedir aynı zamanda Forex piyasasında da işlem hacmi yüksek enstrümanlar arasında bulunmaktadır. Ham Petrol'e olan ilgiyi artıran etkenler arasında Forex piyasasında petrol ticaretinin çok kolay olması, fiyatların hem düşüşüne hem yükselişine yatırım imkanının bulunmasıdır [21].

Teksas petrolü olarak da bilinen "Western Texas" sonuç itibariyle Ham Petrol fiyatları altın/dolar paritesini doğrudan etkileyen önemli bir nitelik olarak karşımıza çıkmaktadır. Bu anlamda önceki günün en yüksek ve en düşük değerinin ortalaması alınarak giriş verisi olarak kullanıldı. Ham Petrol değerlerine ait belli zaman aralığında kullanılan veri Şekil 2’de gösterilmiştir.

Ham Petrol WTI Vadeli İşlemleri Geçmiş Verileri

Zaman: Haftalık Verileri İndir 01/01/2015 - 30/11/2020

Tarih :	Şimdi :	Açılış :	Yüksek :	Düşük :	Hac. :	Fark % :
29.11.2020	46,26	45,34	46,68	43,92	1,41M	1,60%
22.11.2020	45,53	42,46	46,26	42,29	1,14M	8,02%
15.11.2020	42,15	40,17	42,46	40,15	817,62K	5,03%
08.11.2020	40,13	37,34	43,06	37,16	1,92M	8,05%
01.11.2020	37,14	35,24	39,35	33,64	1,64M	3,77%
25.10.2020	35,79	39,69	39,83	34,92	2,15M	-10,19%
18.10.2020	39,85	40,69	41,70	39,57	1,04M	-2,52%
11.10.2020	40,88	40,40	41,29	39,04	1,37M	0,69%
04.10.2020	40,60	37,00	41,47	37,00	1,95M	9,58%

Şekil 2. Ham Petrol verisi.

2.3 Hisse Senedi Gelirleri (NYSE World Leader Index)

NYSE 200 Endeksi olarak da ifade edilen ve aşağıdaki iki farklı borsa endeksinin kombinasyonu olan bu borsa endeksinin tanımak, kendisini oluşturan her iki endeksin ne olduklarını anlamakla mümkün olur.

NYSE U.S 100 Endeksi:

NYSE'de kote edilen toplam piyasa değerleri en büyük olan 100 şirketten oluşur.

NYSE International 100 Endeksi:

NYSE'nin toplam piyasa değeri en yüksek ve Amerikan olmayan 100 şirketten oluşmuştur.

NYSE World Leaders Endeksi:

Önceden ifade edildiği üzere NYSE US100 ve NYSE Uluslararası 100 endeksinin bir kombinasyonudur. En büyük 200 şirketin performansını yansıtır [22]. Bu hisse senedi gelirleri işlem hacimlerinin büyük olması sebebiyle doğrudan ve dolaylı olarak altın/dolar paritesini etkileyen diğer nitelikleri de etkilemesi açısından incelenen parite için önemli bir değişken konumundadır. Bu nedenle önceki günün en yüksek ve en düşük değerinin ortalaması alınarak giriş verisi olarak kullanıldı. Belirtilen tarih aralığında kullanılan *Hisse Senedi Gelirleri* verilerine ait örnek olarak Şekil 3'te gösterilmiştir.

NYSE World Leaders Geçmiş Verileri

Zaman: Haftalık Verileri İndir 01/01/2015 - 30/11/2020

Tarih :	Şimdi :	Açılış :	Yüksek :	Düşük :	Hac. :	Fark % :
29.11.2020	9.388,68	9.259,41	9.388,77	9.116,31	-	1,40%
22.11.2020	9.259,41	9.025,14	9.298,68	9.025,14	-	2,60%
15.11.2020	9.025,14	9.025,07	9.159,93	8.965,78	-	0,00%
08.11.2020	9.025,07	8.707,92	9.149,66	8.707,92	-	3,64%
01.11.2020	8.707,92	8.201,16	8.738,14	8.201,16	-	6,18%
25.10.2020	8.201,16	8.700,75	8.700,75	8.111,92	-	-5,74%
18.10.2020	8.700,75	8.710,42	8.760,97	8.590,79	-	-0,11%
11.10.2020	8.710,42	8.781,44	8.850,85	8.574,24	-	-0,81%
04.10.2020	8.781,44	8.467,17	8.806,94	8.467,17	-	3,71%

Şekil 3. Hisse Senedi Gelirleri verileri.

2.4 ABD Tahvil Faizleri

Amerikan tahvil piyasası dünyanın en büyük tahvil piyasasıdır ve çalkantılı dönemlerde uluslararası yatırımcılar tarafından güvenli liman olarak görülmektedir. ABD tahvil faiz oranlarının artması özellikle gelişmekte olan ülkeler diğer ülkelerden para çıkışı olarak algılanmaktadır. Bu açıdan finansal entegrasyon, risk yönetiminin önemini artırmış ve yatırımcıların uluslararası portföy çeşitlendirmesine ilgi duymalarını sağlamıştır [23].

Tahvil faizi değerleri de yatırımcılar içerisinde özellikle büyük hacimli finansal hareketlilikleri olan kurumların karar vermeden önce dikkate aldığı bu haliyle altın fiyatlarını doğrudan etkileyen ve etki oranı göz önüne alınması itibarıyla çalışmaya dahil edilmiş bir niteliktedir. Dolayısıyla önceki günün en yüksek ve en düşük değerinin ortalaması alınarak giriş verisi olarak kullanıldı. ABD Tahvil Faizlerine ait, belli tarih aralığında kullanılan veriler Şekil 4'te gösterilmiştir.

ABD 10 Yıllık Tahvil Faizi Geçmiş Verileri

Zaman: Haftalık Verileri İndir 01/01/2015 - 30/11/2020

Tarih :	Şimdi :	Açılış :	Yüksek :	Düşük :	Fark % :
29.11.2020	0,973	0,845	0,986	0,831	15,47%
22.11.2020	0,842	0,832	0,900	0,826	2,17%
15.11.2020	0,824	0,900	0,931	0,818	-8,20%
08.11.2020	0,898	0,830	0,975	0,798	9,49%
01.11.2020	0,820	0,855	0,945	0,718	-6,13%
25.10.2020	0,874	0,828	0,877	0,746	3,85%
18.10.2020	0,841	0,759	0,872	0,754	12,34%
11.10.2020	0,749	0,760	0,769	0,691	-3,83%
04.10.2020	0,779	0,710	0,799	0,699	10,64%

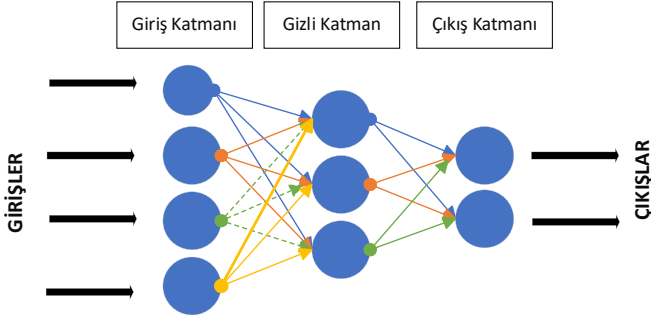
Şekil 4. ABD Tahvil Faiz verileri.

2.5 Gümüş Fiyatları

Gümüş, Emtia piyasalarının değerli metallerinden biridir. İlk çağlarda ziynet eşyası olarak kullanımının yanında "sikke" olarak adlandırılan ödeme aracı olarak da kullanılmıştır. En iletken metal olması ve kolay şekil almasından dolayı son yüzyıllarda talebi en yüksek metaller arasında yer almaktadır. Forex piyasasında Altın'dan sonra en fazla işlem gören enstrümanları arasındadır. Global ekonomideki büyüme rakamlarından ve endüstriyel taleplerden diğer emtialar gibi etkilenen Gümüş fiyatları, Altın fiyatları ile korelasyonu yüksek olduğu bilinmektedir [24]. Bu nedenle Gümüş fiyatlarının önceki gün kur değerleri de giriş verisi olarak kullanıldı.

3 Çok Katmanlı Yapay Sinir Ağı (ÇKYSA)

Yapay Sinir Ağları (YSA) birçok biyolojik nörona sahip insan beynine dayalı oluşturulmuş hesaplama modelidir. Sinir Ağı modeli paralel depolama yeteneğine sahip öğelerin işlenmesi için oluşturulan dağıtılmış işlemci gibi bazı önemli bilgileri yaratarak ve kullanıma hazır hale getirir. Böylece insan beyni gibi davranmış olur kısaca biyolojik sinir sistemlerinin işleme yeteneklerini taklit etme girişimidir. Giriş ve çıkış verileri de dahil olmak üzere bir ağ birbirine bağlı çok sayıda yapay nörondan oluşmaktadır. Paralel olarak çalışabilen çok sayıda, çok basit işleme elemanını birbirine bağlayarak karmaşık işlem görevlerini gerçekleştirebilen sistemleri gerçekleştirmek temel fikri oluşturmaktadır. Giriş verilerine göre arada oluşturulan bağlantıların gücünü yeterince ayarlayarak sorunları çözmeyi öğrenir. Sinir ağı modellerinden biri olan ve bu çalışmada kullanılan çok katmanlı yapay sinir ağının yapısını oluşturan ana model Şekil 5 de verilmiştir.



Şekil 5. YSA genel mimari yapısı [20].

Sinir ağı mimarisi oluşturulurken en önemli faktör mimari içerisinde oluşturulacak ve kullanılacak sayısal değerlerin, modelde kullanılan parametrelerinin belirlenmesidir. Genel olarak aşağıda belirtilen ana unsurlar oluşturulan modelin performansını önemli ölçüde etkilemektedir.

- 1) Gizli katman sayısı ve bu katmanda kullanılacak nöron sayısı.
- 2) Kullanılacak öğrenme algoritması,
- 3) Kullanılan öğrenme algoritmasına bağlı olarak istenilen parametrelerin belirlenmesi.
- 4) Kullanılacak aktivasyon fonksiyonu.
- 5) Ağırlıkların güncelleştirilmesi. Her bir katmanda kullanılan başlangıç ağırlık değerlerinin belirlenmesi.
- 6) Performans ölçütü.
- 7) Tahmin.

Oluşturulacak olan modelin her bir probleme ait olan giriş katmanı ve çıkış katmanında bulunan nöron sayıları bellidir. Özellikle tahmin problemlerinin temeli nedensellik olduğu için kullanacak olan girdi nöron sayısı o belirtilen bağımsız değişken sayısı kadardır. Asıl amaç, oluşturulan sinir ağı modelinde gizli katman sayısının ve her bir katmanda kullanacak nöron sayısının belirlenmesidir. Giriş ve çıkış katmanları arasında bulunan gizli katman sayısı modelde kullanılan veri sayısına göre farklı sayıda olabilir. Öğrenme ve genelleme olayının doğru gerçekleşmesi için katman sayısının ve her bir katmanda kullanacak nöron sayısı önemlidir. Her gizli katmandan alınan ağırlıklandırılmış giriş toplamları aktivasyon fonksiyonuna verilerek ilgili katmandan çıkarılır ve diğer katmana giriş olarak verilir.

Aktivasyon fonksiyonu oluşturulan yapay sinir ağı modelinde elimizde bulunan girdinin ağırlıklı toplamının ağırlık bir katmanında bulunan düğümünden çıktıya nasıl dönüştüğünü tanımlar. Kısacası oluşturulan modelde etkinleştirme işlevidir ve çok önemlidir.

Sonuç olarak mevcut ağırlıkların ulaştırdığı sonuç gerçek sonuç ile kıyaslanarak kullanılan algoritmaya göre iyileştirme yapılabilir veya öğrenme tamamlanabilir. Yaygın olarak kullanılan öğrenme algoritmalarından biri Geri Yayılım Algoritmasıdır (Back Propagation Algorithm). Kullanılan eğitim algoritmaları oluşturulan modelinin doğruluğunu optimize etmek için çok önemlidir. Birçok eğitim algoritması olmakla birlikte bu çalışma kapsamında Levenberg-Marquardt, Bayesian Regularization ve One-step secant algoritmaları kullanılmıştır.

4 Metot

4.1 Verilerin Elde Edilmesi

Bu çalışma kapsamında 01.01.2015-30/11/2020 tarih aralığında kullanılan veriler (değişkenler) ve kaynaklarla ilgili bilgi Tablo 1 de verilmiştir. Yapay Sinir Ağı'nın eğitiminde kullanılan giriş verileri "tr-investing.com" sitesinden alınmıştır. Veriler istenilen bir tarih aralığı için; günlük, haftalık veya aylık bulmak mümkündür. Her bir tarih için anlık değer, açılış değeri, bir de ilgili tarihteki en yüksek ve en düşük değerler gibi birden fazla değer kaydedilmiş olarak bulunması, verilerin kullanılabilirliği açısından makul tek bir değer ile ifade edilmesini zorunlu kılmaktadır. Bu amaçla her bir tarih için en yüksek ve en düşük değerlerin aritmetik ortalaması alındı. Daha sonra tarihsel sıralamaları dikkate alınarak bir zaman serisi biçiminde düzenlendi. Böylece, verileri Matlab'a aktarırken kolay bir şekilde dosyadan okuma ile alınması bakımından uygun hale getirildi.

Tablo 1. Araştırmada Kullanılan Değişkenler.

Değişken	Birim	Veri Sıklığı	Simge	Kaynak
Altın	\$/Ons	Günlük	XAU/USD	tr-investing.com
Ham Petrol	\$/Varil	Günlük	WTI	tr-investing.com
ABD Tahvil Faizleri	% Oran	Günlük	ABD 10Y	tr-investing.com
Gümüş	\$/Ons	Günlük	XAG/USD	tr-investing.com
NYSE World Leaders Endeksi	\$	Günlük	NYSE 200	tr-investing.com

4.2 Normalizasyon

Yapay Sinir Ağları ile eğitim işleminden önce verilerin Normalize edilmesi gerekir. En önemli sebeplerinden biri farklı skalalarda olan verilerin ağırlıklar ile çarpılıp toplanmaları sonucu düşük değerlikler arasında değişiklik gösteren önemli nitelikler ihmal edilecek kadar etkisiz hale gelir. Bu durumda doğru bir öğrenme gerçekleşmez ve doğru sonuçlar elde edilemez. Bu nedenle eğitime geçmeden önce aşağıda detayı verilen *Min-max* Normalizasyonu işlemi yapılmıştır.

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

- X : Normalize edilmiş X değerleri vektörü
 X' : Normalize edilmemiş X değerleri vektörü
 X_{min} : X vektörünün en küçük değerli elemanı
 X_{max} : X vektörünün en büyük değerli elemanı

Her bir değişkene ait veri sütunu için Maksimum ve Minimum satırlar belirlendi. Bunların farkı alınarak çarpmaya göre tersi ile her bir satırın kendi sütunu dahilindeki Minimum değerle farkı ile çarpılarak Normalizasyon işlemi gerçekleştirildi.

A sütununda ilk satır A1, son satır A309 olmak üzere;

$$(1 / (MAX - MIN)) * (A1 - MIN)$$

$$(1 / (MAX - MIN)) * (A2 - MIN)$$

$$(1 / (MAX - MIN)) * (A2 - MIN)$$

.....

.....

$$(1 / (MAX - MIN)) * (A308 - MIN)$$

$$(1 / (MAX - MIN)) * (A309 - MIN)$$

Bu şekilde işleme alınan satır, vektörün minimumu olduğunda ifadenin değeri 0 (sıfır), maksimumu olduğunda ise ifadenin değeri 1 (bir) olur. Böylece değişkenlere ait alınan ve 0 ile 1 aralığına göre *normalize* edilen veriler oluşturulan sinir ağı modeline giriş olarak verilmeye hazır hale getirilmiştir.

5 Performans Değerlendirme Kriterleri

Bu çalışma kapsamında kullanılan verilerin %70'i Eğitim (Training), %15'i doğrulama (Validation), ve

%15'i Test için ayrılmıştır. Çalışmada oluşturulan farklı YSA mimarilerinin performans değerlendirmesi; Belirleme Katsayısı (R Kare- R^2), Karesel Hata Ortalama Karekökü (RMSE), Ortalama Mutlak Hata (MAE) ve Ortalama Mutlak Yüzde Hata (MAPE) dört farklı hata analiz yöntemi kullanılarak gerçekleştirilmiştir.

Esas itibarıyla oluşturulan ağı kullanılan herhangi bir modelden sonra verdiği tahmin sonuçlarının karşılaştırılmasında yaygın olarak Belirleme Katsayısı (R^2) dikkate alınır. Veri sayısının fazla olması durumunda karşılaşılan yanıltıcı etkiyi ortadan kaldırmakla birlikte yanlış değerlendirmelerin önüne geçmek için diğer yöntemler kullanılmıştır.

5.1.1 R Kare (Belirleme Katsayısı- R^2)

Toplam karesel hatanın; gerçekleşen değerlerin, kendi ortalamalarına olan uzaklıklarının karelerinin toplamına, oranının 1'den farkıdır [24].

Hatanın analizinde kullanılan bu formül gerçek kur değerleriyle oluşturulan YSA modelinden elde edilen tahminleri kıyaslamada kullanılmıştır. Bu değer, 1'e yakınlığı ölçüsünde tahminin doğruluğunu ifade eder. Sıfıra yakın olması, tahmin edilen değer, gerçek değere uzak olması anlamına gelir.

Belirleme Katsayısı Regresyon yapılırken eğri uydurmanın daha doğru gerçekleştirilmesinde kullanılan güçlü bir yöntemdir [25]. Bu nedenle Modellerin iyileştirilmesi sürecinde bu metrik kullanıldı. Ancak daha önceden de ifade edildiği üzere, veri sayısının çokluğunun modeli başarısını gerçekte olduğundan fazlasını yansıttığının önüne geçmek ve böylelikle çalışmayı daha doğru sürdürebilmek için R^2 ile detayı verilen başka metrikler de kullanıldı.

Bu hata analiz yöntemi, hatanın sapmasının, gerçekleşen değerlerin standart sapmasına oranının kullanılmasıyla gerçekleştirilir.

$$R \text{ Kare} = \left(\frac{\sum_{n=1}^N (Y[n] - \hat{Y}[n])^2}{\sum_{n=1}^N (Y[n] - \mu_Y)^2} \right) \quad (2)$$

Y: Gerçek kur değer vektörü.

\hat{Y} : YSA'nın bulduğu kur tahminleri vektörü.

μ_Y : Gerçek kur değeri vektörünün ortalaması.

5.1.2 Karesel Ortalama Karekökü (RMSE)

Gerçek değer, ilgili gün için yapılan tahmin değerinden farkı hatayı verir. Bu farkın karesi karesel hatayı verir. Tüm veri için bu farkların aritmetik ortalamasının karekökü Karesel Hata Ortalaması Karekökünü (RMSE) verir. Böylece her bir veri için ortalama hata bulunur.

$$RMSE = \left(\frac{1}{N} \sum_{n=1}^N (Y[n] - \hat{Y}[n])^2 \right)^{1/2} \quad (3)$$

Y: Gerçek kur değer vektörü.

\hat{Y} : YSA modelinin bulunduğu gerçek kur tahmin vektörü.

Bu değer, sifıra yakın mümkün olan en küçük değer olması tahminin gerçekleşen değere yakın olması anlamına gelir. Tahmin edilen değer gerçek değere eşit ise zaten RMS sifır olur.

5.1.3 Ortalama Mutlak Hata (MAE)

Gerçekleşen değer ile tahmin edilen değer farkı hatayı verir. Ancak bu değer negatif olmaması için mutlak değer alınması gerekir. Çünkü bu işlem, gerçek değerler vektörü ile tahmin değerleri vektörünün her bir elemanı için yapılarak, bunların toplamlarının, eleman sayısına bölünmesi ile hatanın ortalamasının bulunması amaçlanmaktadır. Negatif değerlerin pozitif değerlerle toplanması sonucu hata bilgisinin kısmen veya tamamen kaybedilmesi sorunu bu şekilde ortadan kaldırılmış olur. Bu değer mümkün olduğunca küçük bir sayı çıkması istenir.

$$MAE = \frac{1}{N} \sum_{n=1}^N |Y[n] - \hat{Y}[n]| \quad (4)$$

Y: Gerçek kur değeri vektörü.

\hat{Y} : YSA'nın bulunduğu kur tahminleri vektörü

N: Y ve \hat{Y} vektörlerinin her birinde olan eleman sayısı.

5.1.4 Ortalama Mutlak yüzde Hata (MAPE)

Gerçekleşen değer ile tahmin edilen değer farkının yine gerçekleşen değere bölünmesi hatayı yüzde olarak verir. Ancak bu değer negatif olmaması için mutlak değer alınması gerekir. Çünkü bu işlemin, gerçek değerler vektörü ile tahmin değerleri vektörünün her bir elemanı için yapılarak, bunların toplamlarının, eleman sayısına bölünmesi ile yüzde hatanın ortalamasının bulunması amaçlanmaktadır.

Negatif değerlerin pozitif değerlerle toplanması sonucu hata bilgisinin kısmen veya tamamen kaybedilmesi sorunu bu şekilde ortadan kaldırılmış olur. Böylece her bir veri için, ortalama hata, yüzde olarak bulunur. Hatayı ifade etmesi itibarıyla, bu değer mümkün olduğunca sifıra yakın bir sayı çıkması istenir.

$$MAPE = 100\% \frac{1}{N} \sum_{n=1}^N \left| \frac{Y[n] - \hat{Y}[n]}{Y[n]} \right| \quad (5)$$

Y: Gerçek kur değeri vektörü

\hat{Y} : YSA'nın bulunduğu kur tahminleri vektörü

N: Y ve \hat{Y} vektörlerinin her birinde olan eleman sayısı

6 Deneyle ve Tartışma

Bu çalışma kapsamında oluşturulan sinir ağı modelinde en iyi performans gösteren YSA modeli belirlenirken aşağıda belirtilen 3 durumun farklı kombinasyonları denenerek en iyi YSA modeli seçilmiştir.

Farklı öğrenme algoritmaları;

Levenberg-Marquardt

Bayesian Regularization

One Step Secant

Gizli katman sayısı ve bu katmanda bulunan nöron sayısı;

1 Gizli Katman 3 Nöron

1 Gizli Katman 5 Nöron

2 Gizli Katman, 1. Katman da 3 Nöron, Katman da 3 Nöron.

Farklı aktivasyon Fonksiyonları;

Hyperbolic Tangent

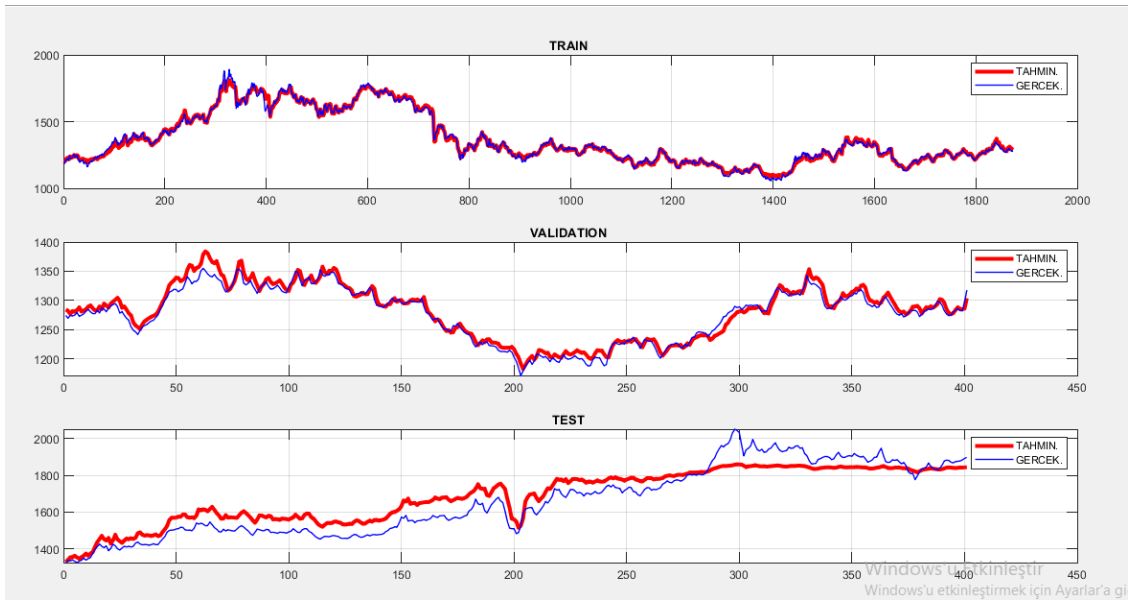
Sigmoid

Bu çalışmada beş adet niteliğe ait 1675 farklı verinin %70'i eğitim, %15 test ve son olarak %15'i doğrulama için kullanılmıştır. Öncelikle aktivasyon fonksiyon seçimi için birkaç eğitim algoritması kullanıldıktan sonra, iyi sonuçların alındığı Bayesian Regularization eğitim algoritması kullanılarak oluşturulan, 1 gizli katman ve 9 nöronun kullanıldığı YSA için performans ölçümleri aşağıda belirtilen Tablo 2 'de verilmiştir. Ayrıca Şekil 6 ve Şekil 7 sırasıyla Log-Sig ve Tan-Sig fonksiyonlarına ait hata grafikleri verilmiştir.

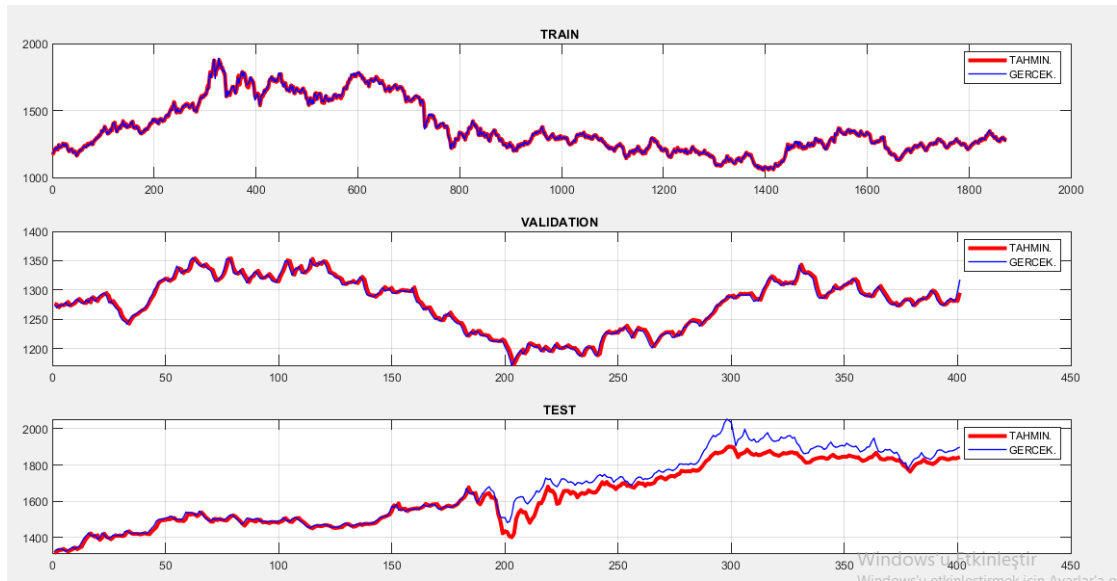
Tablo 2. Aktivasyon Fonksiyon Seçimi.

R KARE	Eğitim	Test	Doğrulama
Log-Sig	0.9924	0.8590	0.9511
Tan-Sig	0.9969	0.9517	0.9818
MAPE	Eğitim	Test	Doğrulama
Log-Sig	0.0087	0.0390	0.0061
RMSE	Eğitim	Test	Doğrulama
Log-Sig	16.8514	70.9940	9.9702
Tan-Sig	10.7407	41.5403	6.0794

Aldığı sonuçları -1 ile +1 arasında ölçekleyen Tan-sig fonksiyonu; aldığı sonuçları 0 ile 1 arasında ölçekleyen Log-sig fonksiyonundan daha iyi sonuçlar vermiştir. Bu nedenle sonraki denemelere Hiperbolik Tanjant Fonksiyonu (Tan- Sig) ile devam edilmiştir.



Şekil 6. Log-sig Aktivasyon Fonksiyonu Hata grafiği.



Şekil 7. Tan-sig Aktivasyon Fonksiyonu Hata Grafiği.

Çalışmanın ilerleyen kısmı yukarıda belirtilmiş olan gizli katman sayısı ve bu katmanda kullanılan farklı nöron sayılarıyla oluşturulan farklı YSA modellerine ait performans değerlendirme sonuçlarından oluşmaktadır. Oluşturulan her bir modele ait R^2 , MAPE, MAE ve RMSE performans değerlendirmeleri Tablo 3, 4 ve 5' te gösterilmiştir.

Performans değerlendirme kriterlerine ait değerlendirme sonuçları incelendiğinde çalışma kapsamında kullanılan verilerle eğitilen ağın her bir katmanda 3 nöron kullanılan 2 gizli katmanlı modelde tüm algoritmalar için iyi denilebilecek sonuçlar elde ettiği gözlemlendi. Birbirine yakın

performans sergileyen algoritmalar için tüm metrikler birlikte değerlendirildiğinde en iyi sonucun Levenberg Marquardt eğitim algoritması ile elde edildiği görülmektedir.

Aynı zamanda bu algoritma kullanılarak oluşturulan 3 Nöronlu ve 5 Nöronlu tek gizli katmanlı ağ modeli ile de benzer başarıda performans sergileyen sonuçlar elde edildiği görülmektedir. Sonuç olarak R^2 , MAPE, MAE ve RMSE metriklerinin tamamı göz önünde bulundurulduğunda 5 nöronu olan 1 Gizli Katmanlı Yapay Sinir Ağının en iyi sonucu verdiği görülmektedir.

Tablo 3.1 Gizli Katman 5 Nöron Performans Değerlendirmesi.

1 Gizli Katman 5 Nöron	EĞİTİM				DOĞRULAMA				TEST			
	R^2	MAPE	MAE	RMSE	R^2	MAPE	MAE	RMSE	R^2	MAPE	MAE	RMSE
Bayesian Regularization	0.99	0.006	7.95	10.86	0.97	0.004	5.35	6.82	0.59	0.053	95.46	121.08
One - step Secant	0.99	0.008	11.1	15.97	0.93	0.008	9.81	11.91	0.69	0.049	85.31	104.0
Levenberg Marquardt	0.99	0.006	8.19	11.42	0.97	0.004	5.41	6.72	0.97	0.013	22.29	27.08

Tablo 4. 1 Gizli Katman 3 Nöron Performans Değerlendirmesi.

1 Gizli Katman 3 Nöron	EĞİTİM				DOĞRULAMA				TEST			
	R^2	MAPE	MAE	RMSE	R^2	MAPE	MAE	RMSE	R^2	MAPE	MAE	RMSE
Bayesian Regularization	0.99	0.006	8.04	11.22	0.96	0.005	6.66	8.37	0.91	0.023	54.93	54.93
One - step Secant	0.99	0.008	10.54	15.13	0.97	0.004	5.59	6.93	0.91	0.024	43.43	56.21
Levenberg Marquardt	0.99	0.006	8.31	11.54	0.979	0.004	5.27	6.53	0.99	0.007	11.2	15.34

Tablo 5. 2 Gizli Katman her Bir Katmanda 3 Nöron Performans Değerlendirilmesi.

2 Gizli Katman 3'er Nöron	EĞİTİM				DOĞRULAMA				TEST			
	R ²	MAPE	MAE	RMSE	R ²	MAPE	MAE	RMSE	R ²	MAPE	MAE	RMSE
Bayesian Regularization	0.99	0.006	7.92	10.74	0.98	0.004	4.86	6.08	0.95	0.016	29.23	41.54
One - step Secant	0.99	0.006	8.78	12.17	0.96	0.006	7.23	8.75	0.95	0.018	30.46	39.66
Levenberg Marquardt	0.99	0.006	8.31	11.5	0.97	0.005	5.88	7.23	0.97	0.010	16.7	22.18

7 Sonuç

Günümüz dünyasında bilgisayarlar günlük hayatın her aşamasında kullanılmaktadır. Özellikle gelişen teknolojiyle birlikte, karmaşık hesaplama yöntemlerinin büyük çaplı verilere uygulanabilmesine imkân tanımıştır. Böylece birçok alanda, insanın bilgi ve tecrübesinin yetişemediği sürelerde birtakım sonuçlar elde edilmekte ve bu sonuçlara bağlı karar mekanizmaları oluşturulmaktadır. Bu alanlardan biri de sıklıkla gündemde kalan altın ve dolar paritesi ve buna bağlı kur tahminlerinin yapılmasıdır.

Şimdiye kadar yapılmış olan çalışmalar incelendiğinde kur tahmini için çok farklı parametreler ve yöntemler kullanılmıştır. Yapılmış olan bu çalışma kapsamında verilen değişkenlerin, öznitelik olarak kullanılmasıyla Çok Katmanlı Yapay Sinir Ağı eğitilerek Regresyon analizi gerçekleştirilmiş, böylece altın/dolar paritesinin sonraki kur tahmini yapılması incelenmiştir.

Bu çalışmanın diğer yapılmış olan çalışmalardan farklı yönü çok katmanlı sinir ağı modeli oluşturulurken kullanılan farklı parametrelerin denenmesidir. Farklı öğrenme algoritmalarının performans değerlendirmelerinin yapılmasının yanında YSA mimarisinde önemli rolü olan ve model performansını ciddi ölçüde etkileyen gizli katman sayısı ve bu katmanda kullanılan nöron sayılarının farklı kombinasyonları denenmiştir. Ayrıca oluşturulan modeli etkinleştirme işlevi olarak tanımlanan ve önemli bir rolü olan aktivasyon fonksiyonları karşılaştırılmıştır.

Bu çalışmanın en önemli amacı; Levenberg-Marquardt, Bayesian Regularization ve One-step secant gibi farklı öğrenme algoritma performansları; farklı gizli katman sayıları, bu katmanlarda kullanılan farklı nöron sayıları ve farklı aktivasyon fonksiyonları kullanılarak karşılaştırılmıştır. Performans metriği olarak belirleme katsayısı (R Kare) ortalama mutlak hata (MAE), mutlak ortalama

yüzde hata (MAPE) ve ortalama hata karekökü (RMSE) kullanıldı. Çalışmadaki en iyi sonuç, 2 gizli katmanlı her bir katmanda 3 nöron bulunan ve Levenberg Marquardt eğitim algoritması kullanılarak elde edildi. (R²: 0.97, MAPE: 0.005, MAE:5.88, RMSE:7.23).

Yapılan çalışma neticesinde geçmiş veriler kullanılarak incelenen paritenin geriye yayımlı çok katmanlı yapay sinir ağları ile tahmini; uzun yıllar süren tecrübe yoluyla ulaşılabilecek nitelikte bir sonuç olduğu söylenebilir. Ayrıca doğru özniteliklerin, uygun sayıda katman ve nöron sayısının kullanılmasının tercih edilen algoritmanın performansını iyileştirdiği gözlemlendi. Bu anlamda karar mekanizması mahiyetindeki ağırlık katsayılarının daha doğru düzeylere çekilebileceği anlaşıldı.

Kaynaklar

- [1] İnciyan M. Altın. Yüksek Lisans Tezi. İstanbul Üniversitesi. İstanbul. Türkiye. 1994.
- [2] Gezgın YE. Altın Mübadele İşlemleri. Doktora Tezi. Necmettin Erbakan Üniversitesi. Konya. 2019.
- [3] Başar R, Saraç, M. "GLOBAL ALTIN ARZ-TALEBİ VE ALTIN PİYASALARI ÜZERİNE BİR DEĞERLENDİRME". Elektronik Sosyal Bilimler Dergisi ,20(80),2240-2260.2021DOI: 10.17755/esosder.853142
- [4] Syzdykova A. "DÜNYA ALTIN FİYATLARINI ETKİLEYEN
- [5] FAKTÖRLERİN ANALİZİ". Avrasya Sosyal ve Ekonomi Araştırmaları Dergisi. 5(11). 1-13. 2018
- [6] Syzdykova A. "Dünya Altın Fiyatlarını Etkileyen Faktörlerin Analizi". Avrasya Sosyal Ve Ekonomi Araştırmaları Dergisi, 5-11, 1-13,2008.
- [7] Doğanalp N. Konya S. Kabaloğlu G. "TÜRKİYE'DE ALTIN FİYATLARININ BELİRLEYİCİLERİ ÜZERİNE AMPİRİK BİR UYGULAMA". Ordu Üniversitesi Sosyal Bilimler Enstitüsü Sosyal Bilimler Araştırmaları Dergisi, 6 (15), 412-424, 2016.
- [8] Topçu A. "Altın Fiyatlarını Etkileyen Faktörler". SERMAYE PİYASASI KURULU ARAŞTIRMA RAPORU. Ocak 2010.

- [9] Sjaastad LA, "The price of gold and the exchange rates: Once again". Resources Policy. 33(2) ,118-124. 2008. <https://doi.org/10.1016/j.resourpol.2007.10.002>
- [10] Topçu A. "Altın Fiyatlarını Etkileyen Faktörler". Spk Araştırma Raporu, Ankara, Türkiye, 2010.
- [11] Küçükaksoy I, Yalçın D. "Altın Fiyatlarını Etkileyebilecek Faktörlerin İncelenmesi". Ekonomik Ve Sosyal Araştırmalar Dergisi 13, 1-20, 2017.
- [12] "Altın Fiyatlarını Etkileyen Faktörler | Investaz Blog". <https://www.investaz.com.tr/blog/altin->
- [13] Fiyatlarını-Etkileyen-Faktörler/ (02.02.2021).
- [14] Söylemez, Y. "Çok Katmanlı Yapay Sinir Ağları Yöntemi İle Altın Fiyatlarının Tahmini". Sosyoekonomi 28, 271-291, 2020.
- [15] Çam S., Kılıç S. "Altın Fiyatı Günlük Getirilerinin Yapay Sinir Ağları Algoritması Ve Markov Zincirleri Modelleri İle Tahmini". Uluslararası İktisadi Ve İdari İncelemeler Dergisi 18. Eyi Özel Sayısı, 681-694,2018.
- [16] Yüksel R, Akkoç S." Altın Fiyatlarının Yapay Sinir Ağları İle Tahmini Ve Bir Uygulama". Doğu Üniversitesi Dergisi, 17(1), 39-50,2016.
- [17] Yazdani-Chamzini A. Yakhchali S. H Volungeviçienė D. And Zavadskas E K. "Forecasting Gold Price Changes By Using Adaptive Network Fuzzy Inference System". Journal Of Business Economics and Management, 13(5), 994-1010,2012.
- [18] Tekin BF. "DÖVİZ KURU TAHMİNİNDE YAPAY SİNİR AĞLARI VE ÇOKLU DOĞRUSAL REGRESYON ANALİZİ PERFORMANS KARŞILAŞTIRMASI". Yüksek Lisans Tez. Sivas Cumhuriyet Üniversitesi. Sivas. Türkiye.2019.
- [19] Ozkan F. "Döviz Kuru Tahmininde Parasal Model ve Yapay Sinir Ağları Karşılaştırması". İşletme ve Ekonomi Araştırmaları Dergisi. 3(1),27-39,2012.
- [20] Tas O. Yakak E. Ugurlu U. "Euro/tl Kuru Tahmininde İstatistik ve Yapay Sinir Ağları Kullanımı". 4th Global Business Research Conference. 7,414-417. 2018. DOI: 10.17261/Pressacademia.2018.926
- [21] Menzies T. Kocagüneli E. Minku L. Peters F. Turhan B. "Chapter 24 - Using Goals in Model-Based Reasoning". Sharing Data and Models in Software Engineering. 321-353,2015. <https://doi.org/10.1016/B978-0-12-417295-1.00024-2>
- [22] Sivalingam K C. Mahendran S, & Natarajan S. "Forecasting Gold Prices Based On Extreme Learning Machine". Int. J. Comput. Commun. Control, 11, 372-380, 2016.
- [23] "Xau Usd Veri Geçmişi". <https://tr.investing.com/currencies/xau-usd-historical-data> (01.02.2021).
- [24] "New York Menkul Kıymetler Borsası", https://tr.wikipedia.org/wiki/New_York_Menkul_K%C4%B1ymetler_Borsası (02.02.2021).
- [25] B Eyüboğlu, S."Amerikan 10 Yıllık Tahvil Faizleri İle Gelişmekte Olan Ülke Borsaları Arasındaki İlişkinin Test Edilmesi". Yönetim Bilimleri Dergisi, 16.31, 443-459,2018.
- [26] Veri Bilimi Okulu". <https://www.veribilimiokulu.com/blog/r-kare-ve-duzel>.(2021)
- [27] Koc, T. & Akın, P. (2022). Estimation of High School Entrance Examination Success Rates Using Machine Learning and Beta Regression Models. Journal of Intelligent Systems: Theory and Applications, 5 (1) , 9-15 ,2022. DOI: 10.38016/jista.922663.