



YAPAY SİNİR AĞLARI İLE BİST ELEKTRİK ENDEKSİ FİYAT TAHMİNİ ÜZERİNE BİR ARAŞTIRMA

DİDAR GÜÇLÜ^{1*} & VELİ AKEL²

¹Yüksek Lisans Öğrencisi, Erciyes Üniversitesi, Sosyal Bilimler Enstitüsü, ddruguclu@gmail.com, <https://orcid.org/0009-0002-6742-6762>. ²Prof. Dr., Erciyes Üniversitesi, İktisadi ve İdari Bilimler Fakültesi, İşletme Bölümü, veliakel@erciyes.edu.tr, <https://orcid.org/0000-0002-5723-0910>.

Bu çalışma "Yapay Sinir Ağları ile Hisse Senetlerinin Fiyat Tahmini: BİST Elektrik Endeksi Örneği" isimli yüksek lisans tezinden üretilmiştir.

ÖZ

Bu çalışmada Ocak 2004- Mart 2024 döneminde, Yapay Sinir Ağları Yöntemiyle BİST Elektrik (XELKT) Endeksinin fiyat tahmini çeşitli modellerle yapılmıştır. Oluşturulan modellerde Euro, Dolar, Gram Altın, Brent Petrol, Tüketici Fiyat Endeksi ve BİST100 değerleri bağımsız değişkenler, XELKT Endeksi bağımlı değişken olarak belirlenmiştir. Farklı eğitim ve test oranlarına göre farklı eğitim fonksiyonları, farklı gizli katman sayıları ve gizli katmanlardaki nöron sayıları değiştirilerek en iyi tahmin başarısına sahip model belirlenmiştir. Oluşturulan modellerin öngörü performansı Ortalama Kare Hata, Ortalama Mutlak Yüzde Hata ve Kök Ortalama Kare Hata ölçütleri ile incelenmiştir. Regresyon analizi sayesinde gerçek fiyat ile ulaşılan fiyatın ilişkisini gösteren R değerleri hesaplanmıştır. Sonuç olarak Yapay Sinir Ağları Yönteminin XELKT Endeksi fiyat tahmininde başarılı olduğu tespit edilmiştir.

Anahtar Kelimeler: Fiyat Tahmini, Yapay Sinir Ağları Analizi, BİST Elektrik Endeksi

Editör / Editor:

Ayşe CİNGÖZ,
Erciyes Üniversitesi, Türkiye

***Sorumlu Yazar/ Corresponding Author:**

Didar GÜÇLÜ,
ddruguclu@gmail.com

JEL:

C45, G11, G12.

Geliş: 10 Temmuz, 2024

Received: July 10, 2024

Kabul: 12 Kasım 2024

Accepted: November 12, 2024

Yayın: 30 Aralık 2024

Published: December 30, 2024

Atıf / Cited as (APA):

Güçlü, D. & Akel, V.(2024),
Yapay Sinir Ağları ile BİST Elektrik Endeksi
Fiyat Tahmini Üzerine Bir Araştırma, Erciyes
Üniversitesi İktisadi ve İdari Bilimler Fakültesi
Dergisi, 69, 179-186,
doi: 10.18070/erciyesiibd.1513531

A RESEARCH ON BIST ELECTRICITY INDEX PRICE FORECASTING WITH ARTIFICIAL NEURAL NETWORKS

ABSTRACT

In this study, Artificial Neural Networks are used to predict the prices of BIST Electricity Index (XELKT) with various models in the period January 2004-March 2024. In the models predicted, Euro, Dollar, Gram Gold, Brent Oil, Consumer Price Index and BIST100 values are determined as independent variables, and XELKT is determined as dependent variable. The model with the best prediction success is determined by changing different training functions, different numbers of hidden layers and the number of neurons in the hidden layers according to different training and testing rates. The performance of the predicted models has been examined with the measures of Mean Squared Error, Mean Absolute Percentage Error and Root Mean Square Error. Through regression analysis, R values showing the relationship between the actual price and the achieved price are calculated. As a result, it has been concluded that the Artificial Neural Networks Method is successful in predicting the prices of XELKT.

Keywords: Price Forecasting, Artificial Neural Networks Analysis, BIST Electricity Index


GİRİŞ

Yatırımcıların riske karşı tutumları farklılık göstermektedir. Bazı yatırımcılar daha az risk almayı tercih ederken bazı yatırımcılar ise daha fazla risk almayı tercih edebilirler. Hisse senetleri, devlet tahvilleri, hazine bonoları gibi sabit getirili finansal araçlara göre daha yüksek riske sahip ancak daha yüksek getiri potansiyeli olan ve yatırımcılar tarafından gündün güne daha fazla ilgi gören yatırım araçlarıdır. Diğer taraftan hisse senetlerinde riskin yüksek olması ve geleceğe yönelik belirsizlik durumu yatırımcıların hangi finansal aracı seçmesi gerektiği konusunda kafa karışıklığı yaratabilmektedir. Bu sebeple yatırımcıların seçtikleri hisse senedinin getirilerini öngörebilmeleri o hisse senedine yatırım yapıp yapmamaları konusunda yardımcı olacaktır. Bu konuda literatürde yapılan çalışmalar incelendiğinde Yapay Sinir Ağları'nın başarılı bir performans gösterdiği görülebilmektedir. Bu çalışmada XELKT Endeksi fiyatları Yapay Sinir Ağları (YSA) yöntemiyle tahmin edilmeye çalışılmıştır. Araştırma ve yayın etiğine uyularak hazırlanan bu çalışmada, Yapay Sinir Ağları yönteminin 20 yıllık bir dönem için XELKT Endeksi fiyat tahminindeki başarısı incelenmiştir. Bu sebeple 2004- 2024 yılları için Euro, Dolar, Gram Altın, Brent Petrol, Tüketici Fiyat Endeksi (TÜFE) ve BİST100 endeksi verileri bağımsız değişkenler olarak kullanılmış olup, XELKT Endeksi ise bağımlı değişken olarak seçilmiş ve MATLAB R2024a programı vasıtasıyla gerekli analizler yapılmıştır. Tahmin edilen modellerin başarıları Ortalama Hata Kareleri (MSE), Ortalama Mutlak Yüzde Hata (MAPE) ve Ortalama Hata Kareleri Kökü (RMSE) ölçütleri ile incelenmiştir.

I. YAPAY SİNİR AĞLARI VE YAPISI

Yapay sinir ağları insan beyninin işleyişini örnek alarak oluşturulan ve böylece hafızaya alma, karar verme, öğrenme gibi niteliklerin makinelerle uyarlandığı sistemler olarak tanımlanabilir. Yürtoğlu (2005, s. 4), yapay sinir ağlarının birbirine bağlı nöronların oluşturduğu ağlar olduğunu ve bu ağların öğrenme, bilgiler arasındaki ilişkiyi çözümüleme, bellekte tutma gibi özellikleri olan ve aynı zamanda biyolojik sinir sistemi işleyişini taklit eden programlar olduğunu ifade etmiştir.

ŞEKİL 1 | Yapay Bir Sinir Ağı Yapısı



Kaynak: Elmas (2021, s. 35).

Şekil 1'de görüldüğü üzere yapay sinir ağlarının 5 temel elemanı bulunmaktadır. Bunlar şu şekilde açıklanabilir:

•**Girdi Değerleri:** Girdi değerleri (x_1, x_2, \dots, x_m), yapay sinir hücresine hücrenin dışından veya diğer hücrelerden gelen verileri ifade etmektedir.

•**Ağırlıklar:** Girdi değerlerinin hücreye etkisini belirleyen katsayılarıdır. Her girdi değerinin bir ağırlığı bulunmaktadır. Ağırlık değerinin büyük veya küçük olması ilgili girdi değerinin yapay sinir ağına güçlü veya zayıf bağlandığını buna bağlı olarak önemini belirlemektedir (Elmas, 2021, s. 35).

•**Toplama Fonksiyonu:** Sinir hücresine gelen girdi değeri ve ilgili girdi değerinin sahip olduğu ağırlık değeri çarpılarak ulaşılan sonuçların toplamına eşik değerini ekleyerek aktivasyon fonksiyonuna iletir (Elmas, 2021, s. 35).

•**Aktivasyon Fonksiyonu:** Toplama fonksiyonu sonucu ulaşılan verinin işlenerek oluşacak çıktı değerini belirlemeye yarayan işlevdir (Yanık, 2019, s. 56). Literatürde yaygın kullanılan aktivasyon fonksiyonları Şekil 2'de gösterilmiştir.

ŞEKİL 2 | Yaygın Kullanılan Aktivasyon Fonksiyonları

Fonksiyon Adı	Matematiksel İfadesi	Grafik Gösterimi
Doğrusal Fonksiyon (purelin)	$f(x) = x$	
Sigmoid Fonksiyonu (logsig)	$f(x) = \frac{1}{1 + e^{-x}}$	
Hiperbolik Tanjant Fonksiyonu (tansig)	$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}}$	
Eşik Değer Fonksiyonu (hardlim)	$f(x) = 0 \quad x < 0$ $f(x) = 1 \quad x \geq 0$	

Kaynak: Hamzaçebi (2021, s. 41); Yavuz (2006, s. 22).


•**Hücre Çıktısı:** Sinir hücresine gelen girdi verileri ile gerçekleşen tüm işlemler sonucunda ulaşılan sonuç, yapay sinir hücresinin çıktı değeri olarak tanımlanır.

Yapay sinir ağları; katman sayıları, bağlantı yapısı ve öğrenme şekline göre sınıflandırılmaktadır. Katman sayılarına göre tek katmanlı yapay sinir ağları ve çok katmanlı yapay sinir ağlarıdır.

•**Tek Katmanlı Yapay Sinir Ağları:** Bu tür sinir ağları, sadece girdi değerlerinin yer aldığı girdi katmanı ve sonucun elde edildiği çıktı katmanından oluşmaktadır. Ayrıca her bir girdi değerinin ağırlığı da bulunmaktadır. Çıktı değerinin sıfır olmaması için eşik değeri bulunur ve bu eşik değeri daima +1'dir. Doğrusal problemler için kullanılmaktadır (Karacameydan, 2009, s. 54; Vural, 2007, s. 17).

•**Çok Katmanlı Yapay Sinir Ağları:** Çok katmanlı yapay sinir ağları; girdi katmanı, çıktı katmanı ve bu katmanlar arasındaki bir ya da daha fazla gizli katmandan oluşur. Sinir ağı modelleri oluşturulurken kullanılacak gizli katman sayısının belirlenmesi konusunda kesin bir kural bulunmamaktadır. Araştırmacı çeşitli denemeleri sonucu uygun olan gizli katman sayısına karar verir.

ŞEKİL 3 | Çok Katmanlı Bir Yapay Sinir Ağı



Kaynak: Elmas (2021, s. 52).

Bağlantı sayılarına göre yapay sinir ağları ileri ve geri beslemeli olarak iki grupta incelenir.

•**İleri Beslemeli Yapay Sinir Ağları:** İleri beslemeli yapay sinir ağlarında modele giriş yapan veriler girdi katmanından çıktı katmanına doğru ileri ve tek yönde hareket ederler. Aynı katmanlardaki nöronlar arasında bağlantı yoktur ancak her katmanda yer alan nöronların diğer tüm nöronlara bağlantısı vardır (Aydın, 2019, s. 19; Yanık, 2019, s. 60; Yavuz, 2006, s. 23). Bu mimariye sahip ağlar genellikle sınıflandırma, örüntü tanıma ve örüntü oluşturmada kullanılmaktadır (Yanık, 2019, s. 61).

•**Geri Beslemeli Yapay Sinir Ağları:** Gizli katman veya çıktı katmanından elde edilen verilerin önceki birimlere geri dönüş yapabildiği ağ yapısıdır ve en az bir geri besleme bulunmaktadır (Çanakçı, 2006, s. 24). Aynı katmanda bulunan hücreler arasında olabileceği gibi farklı

katmanlardaki hücreler arasında da geri besleme olabilir (Vural, 2007, s. 25). Yurtoğlu (2005, s. 28), geri beslemeli ağlar döngü içerdikleri için girdi verilerinin karşılığının yavaş oluştuğunu bu sebepten bu yapıdaki ağların eğitim sürecinin daha uzun olduğunu açıklamıştır. Yapay sinir ağları öğrenme şekline göre öğretmenli öğrenme, öğretmensiz öğrenme ve takviyeli- destekleyici öğrenme olarak gruplandırılmaktadır.

•**Öğretmenli- Danışmanlı Öğrenme:** Bu öğrenme türünde yapay sinir ağı modeline hem girdi verileri hem de hedeflenen çıktı verileri bir öğretmen- danışman tarafından sunulmaktadır. Analiz sonucu modelin ulaştığı sonuç ile hedeflenen sonuçlar karşılaştırılarak hata oranı hesaplanır. Hata oranını azaltmak amacıyla sinir ağındaki ağırlık değerleri değiştirilir. Bu durum hata oranı en uygun düzeye gelince eğitim tamamlanmaktadır (Yanık, 2019, s. 62).

•**Öğretmensiz- Danışmansız Öğrenme:** Öğretmensiz öğrenmede eğitime yardımcı öğretmen bulunmamaktadır. Sinir ağına hedef çıktı verileri sunulmadan yalnızca girdi değerleri sisteme dahil edilerek bağlantının sinir ağı tarafından kurulması beklenir. Burada yapay sinir ağı modeli ağırlık değerlerini kendisi belirler (Korkut, 2019, s. 24; Yanık, 2019, s. 62).

•**Destekleyici-Takviyeli Öğrenme:** Yapay sinir ağı modeline bir öğretmen yardımcı olurken hedeflenen çıktı verilerini sinir ağına tanıtmamaktadır. Modelin ulaştığı çıktı verisinin olumlu ya da olumsuz olduğuna dair sinyal üretilerek ağırlık değerlerinin düzenlenmesi sağlanmaktadır (Hamzaçebi, 2021, s. 33).

II. LİTERATÜR DEĞERLENDİRMESİ

Yapay Sinir Ağlarının kümeleme, sınıflandırma, örüntü tanıma, tahmin gibi birçok uygulama alanı olduğu bilinmektedir. Yapay sinir ağları yöntemi işletme ve finans alanında gelecekteki fiyat, mali başarısızlık, döviz kuru ve talep tahminleri gibi birçok konuda araştırmalarda kullanılan bir analiz yöntemidir. Bu bölümde yapay sinir ağı yöntemiyle finans alanında yapılan çalışmalara yer verilmiştir. Chen, Leung ve Daouk (2003), Olasılıksal Sinir Ağı modelini kullanarak Tayvan Menkul Kıymetler Borsası piyasa endeksi getirisini tahmin etme ve yönünü modellemeye çalışmışlardır. Ocak 1982- Ağustos 1992 dönemine kadar olan süreci kapsamakta olup Ocak 1982- Ağustos 1987 ve Eylül 1987- Ağustos 1992 olmak üzere iki döneme ayrılmaktadır. Ocak 1982- Ağustos 1987 aralığındaki dönem örneklem içi tahmin dönemi olarak model seçimi ve doğrulama amacıyla, ikinci grup olan Eylül 1987- Ağustos 1992 dönemi ise örneklem dışı değerlendirme dönemi olup modellerin tahminlerini karşılaştırmak amacıyla kullanıldığı belirtilmiştir. Kalman Filtresi ile Genelleştirilmiş Momentler Yöntemi, Rassel Yürüyüş ve YSA modelleri kullanılarak bu üç yöntemin performansı karşılaştırılmıştır. Olasılıksal Sinir Ağı'nın diğer yöntemlere göre getiri yönünü tahminde daha başarılı olduğu açıklanmıştır. Özalp ve Anagün (2003), BIST'te işlem gören Koç Holding'in hisse senetleri fiyatlarının Ocak 96- Aralık 01 dönemine ait verileri dikkate alınarak Çoklu Doğrusal Regresyon Analizi ve Yapay Sinir Ağları ile tahmin etmeye çalışmışlardır. Yapay Sinir Ağları Analizinde ise modeli etkileyen faktörlerin değerlerinin Taguchi Yöntemine göre belirlendiği ve rastgele seçildiği iki analiz yapılmıştır. Araştırma sonucunda tahmin hatalarının düzeyleri, Taguchi Yöntemine göre yapılan YSA analizinde %15.13, modeli etkileyen faktörlerin değerlerinin rassal olarak seçildiği YSA analizinde %34.42 ve belirlilik katsayısı %98.56 olan Çoklu Doğrusal Regresyon Analizinde %32.30 olarak belirlendiği ifade edilmiştir. Tektaş ve Karataş (2004), yaptıkları çalışmada 2002-2003 yıllarını baz alarak 3'ü çimento ve 4'ü gıda sektöründe yer alan 7 adet şirketin hisse senetlerinin fiyat tahmini için doğrusal regresyon ve YSA modelini kıyaslamışlardır. Öncelikle YSA analizi ile günlük ve haftalık verilere göre analiz yapıldığı belirtilmiştir. Günlük verilerle yapılan analizde tahmin başarısında yükselme görüldüğü ifade edilmiştir. Buna bağlı olarak da günlük veriler ile doğrusal regresyon ve YSA modeli korelasyon katsayısı kıyaslanmış ve YSA modeline ait korelasyon katsayısının daha anlamlı olduğu ve hisse senedi fiyat tahminlemesinde YSA modelinin alternatif olabileceği sonucuna ulaşılmıştır. Asilkan ve Irmak (2009), ikinci el otomobillerin gelecekteki fiyatlarını Yapay Sinir Ağları ve Zaman Serisi Analizi yöntemleri ile tahmin etmeye çalışmışlardır. Çalışmada modelin girdi değişkeni olarak 40 adet web sitesindeki Volkswagen, BMW ve Mercedes marka araba modellerinin 12 aylık ve 20.000 km'deki

ilanların Ocak 2005- Aralık 2007 dönemlerindeki 3 yıllık günlük fiyat verilerinin aylık ortalaması ile zaman serileri oluşturulduğu belirtilmiştir. Zaman serisi analizinde R ve SPSS yazılımları kullanılırken, geri yayımlı öğrenme algoritması kullanılan YSA modelinde verilerin %90'ı eğitim %10'u test amaçlı kullanıldığında %70 eğitim %30 test ve %80 eğitim %20 test oranı ile oluşturulan modellere kıyasla en başarılı sonucu elde ettiği görülmüştür. YSA modeline ait diğer bilgiler ise 1 girdi nöronu, 1 gizli katman, 2 gizli nöron, 1 çıktı nöronu, aktivasyon fonksiyonunun Hiperbolik Tanjant olarak belirlenmiş olmasıdır. Araştırma sonucunda her iki yöntemde de Ortalama Mutlak Hata (MAE), Ortalama Mutlak Yüzde Hata (MAPE) ve Ortalama Hata Kareleri Kökü (RMSE) hata fonksiyonlarına göre karşılaştırıldığında YSA'nın Zaman Serisi Analizine göre daha başarılı sonuçlar elde ettiği ifade edilmiştir. Çalışkan ve Deniz (2015), BIST30 endeksindeki 27 hisse senedi fiyat hareketlerini tahmin etmişlerdir. Sonuçta tahminlerde elde edilen ortalama mutlak hata 21 kuruş, ortalama mutlak yüzde hata %1,80 olarak belirlenmiştir. Fiyatların artma- azalma yönündeki tahmin başarısı %58'dir. Yazarlar, endüstri ve firmaya özgü değişkenlerin modelin girdi değişkenlerine eklendiğinde daha başarılı sonuçlar elde edilebileceğini tespit etmişlerdir. Yüksel ve Akkoç (2016), YSA yöntemiyle altın fiyatlarını tahmin etmeye çalışmışlardır. Brent petrol, gümüş, 13 hafta vadeli ABD Hazine Bonusu faiz oranı, ABD TÜFE, EURO/ABD Dolar paritesi, EURO Next100 Endeksi, ABD Dow Jones Endeksi verileri bağımsız değişkenler; altın ons fiyatı ise bağımlı değişken olarak YSA modeline sunulmuştur. Levenberg- Marquardt algoritması ile ve gizli katmanında 2 ve 16 arasında nöron sayısı bulunan YSA modelleri ile tek tek hesaplamalar yapılmış ve R², MAE, MAPE ve RMSE değerleri belirlenmiş buna göre de 16 nöronla hazırlanan modelin en iyi sonuçta sahip olduğu belirtilmiştir. Kosinüs Genlik Metodu altın fiyatını etkileyen etmenleri bulmak amacıyla duyarlılık analizinde kullanılmış ve altın fiyatını en çok gümüş, sonrasında ise sırasıyla; Brent petrol, Dow Jones Endeksi, Euro/ABD Dolar paritesi, Euro Next100 Endeksi, ABD Hazine Bonusu ve ABD TÜFE'nin etkilediği açıklanmıştır. Yiğiter, Sarı ve Başakın (2017) yaptıkları bir araştırmada 2006- 2016 dönemi için hisse senedi fiyatlarını Bulanık Mantık, Yapay Sinir Ağları ve Çoklu Doğrusal Regresyon yöntemleriyle tahmin etmeye çalışmışlardır. Zaman serisi verileri ilk haliyle ham olarak regresyon analizi yapıldığında verimlilik katsayısının 0,570 olduğu belirtilmiş ve sonucun yeterli olmadığı görülerek bazı işlemler sonucunda normal dağılımlı yeni bir zaman serisine ulaşılmış ve bu verilere göre üç yöntem uygulanmıştır. Sonuç olarak YSA modellerinden Levenberg-Marquardt, Scaled Conjugate Gradient ve Bayesian Regularization eğitim fonksiyonlarından bir gün önceden Scaled Conjugate Gradient eğitim fonksiyonuna ve 3 gizli nörona sahip modelin 0,823 verimlilik katsayısı ile diğer YSA modellerinden iyi sonuç verdiği ifade edilmiştir. Çoklu Doğrusal Regresyon modelinin 0,84; Bulanık Mantık yönteminin ise bir gün önceden, iki alt küme ve üçgen üyelik fonksiyonuna sahip model olduğu ve modelin 0,851 verimlilik katsayısına sahip olduğu belirtilmiştir. Sarıkaya (2019), BIST Ulusal 100 endeksinin 2005-2012 dönemlerindeki aylık kapanış fiyatlarını kullanarak 2013'deki aylık kapanış fiyatlarını tahmin etmiştir. Bunun için analizde öncelikle Doğrusal, Logaritmik ve Kübik Regresyon Modelleri oluşturulmuş, modellerin hata kareler ortalaması karekökü değerleri karşılaştırıldığında Kübik Regresyon modelinin hata kareler ortalaması karekökü en düşük değerde bulunmuştur. Daha sonra Kübik Regresyon ve Yapay Sinir Ağları yöntemleri kıyaslanmıştır. Mayıs ayına kadar BIST Ulusal 100 endeksinde artış olduğu, analiz sonucunda Ocak-Mayıs dönemlerindeki tahminler incelendiğinde her iki modelinde bu artışı yansıttığı fakat Yapay Sinir Ağı ile oluşturulan modelin Kübik Regresyona göre gerçeğe daha yakın sonuçlar verdiği ifade edilmiştir. Ancak siyasi ve politik sebepler gibi beklenmeyen ve modele eklenemeyen faktörler nedeniyle her iki modelde de gerçekte Haziran ayı ve sonrasında düşüş ve dalgalanmalar olurken, iki analizin tahmin sonucunda da düşüş gözlemlenmediği belirtilmiştir. Çınaroğlu ve Avcı (2020), 2015-2018 dönemlerindeki günlük verileri kullanarak Türk Hava Yolları'nın hisse senedi fiyatlarını YSA modeli ile tahmin etmeye çalışmışlardır. Araştırmada Çok Katmanlı YSA modellerinde kullanılan Levenberg Marquardt (LM) ve Bayesian Regularization (BR) öğrenme algoritmaları karşılaştırılmış sonuç olarak BR öğrenme algoritmasının tahmin

değerlerinin gerçek değerlere daha uyumlu olduğu ifade edilmiştir. Modelin 10 günlük tahmininde elde edilen MSE, ortalama % hata, minimum % hata ve maksimum % hata değerlerinin sifıra yakın olmasının modelin tahmin performansının yüksek olduğunu kanıtladığı açıklanmıştır. Karakul (2020), BİST 100 Endeksi'ni etkileyen değişkenler arasındaki ilişkilerin modellenmesi amacıyla İleri Beslemeli Geriye Yayılımlı Çok Katmanlı Algılayıcı modeli ile yapay sinir ağı modeli oluşturmuştur. 4.01.2010-7.01.2020 tarihleri arasındaki 2511 işgününe ait veriler kullanılmış, verilerin %90'ı eğitim %10'u test verileri olarak belirlenmiştir. Araştırmada BİST 100 Endeksi verileri bağımlı değişken, gecelik faiz oranı ve dolar kuru ise bağımsız değişkenlerdir. Çalışmada MATLAB 2020a programı kullanıldığı belirtilerek ağı eğitim fonksiyonu Levenberg-Marquardt, Gradient Descent with Adaptive Learning Rate ve One Step Secant; aktivasyon fonksiyonları Momentum ile Azalan Gradyan (Gradient Descent with Momentum- GDM), Azalan Gradyan (Gradient Descent- GD); transfer fonksiyonları Hiperbolik Tanjant Sigmoid (Tansig), Purelin (Lineer), Logaritmik Sigmoid (Logsig) arasında değiştirilerek 18 deney yapılmış ve en iyi sonuç veren modelin R değerine göre Levenberg-Marquardt, Momentum ile Azalan Gradyan ve Tansig fonksiyonlarından oluşan model olduğu belirtilmiştir. Daha sonra bu modele farklı mimarilere sahip 8 YSA modeli oluşturulmuştur. Modellerin performans değerlendirmesi için MAPE değerleri karşılaştırılmıştır. Buna göre 2 gizli katmanlı ve nöron sayıları 2-10-10-1 olan eğitim fonksiyonu LM, aktivasyon fonksiyonu GDM, transfer fonksiyonu tansig olan YSA modelinin tahmin performansının yüksek olduğu açıklanmıştır. Modelin MAPE değeri %7,91 olarak ifade edilmiştir. Koç Ustalı, Tosun ve Tosun (2021) BİST 30 Endeksi'ndeki 22 şirketin 31.01.2010-31.12.2019 tarihleri arasındaki üç aylık finansal tabloları yardımıyla asit-test oranı, cari oran, nakit oran, özsermaye devir hızı, özsermaye kârlılığı, net kâr marjı ve mali yapı oranlarını hesaplayıp analize girdi değerleri olarak eklemiştir. Çıktı verisi ise hisse senetlerinin aylık kapanış fiyatları olup, çıktı verisinin 31.01.2010- 31.12.2019 dönemleri arasındaki aylık kapanış fiyatlarının üç aylık ortalaması hesaplanarak elde edildiği belirtilmiştir. Yapay sinir ağları (YSA), Aşırı Gradyan Artırma (XGBoost) algoritması ve Rastgele Orman (RO) algoritması ile oluşturulan modeller Python dili ile kodlanmış olup modellerin performans göstergesinin R² olarak belirlendiği ifade edilmiştir. Her 3 model de belirlenen parametreler ile 10 kez çalıştırılmış en iyi sonuç ile 10 tekrarın ortalaması tablo ile gösterilmiştir. Modellerden YSA'nın gizli katman sayıları 1 ve 2, gizli katmandaki nöron sayıları 2, 4, 6, 8, 10; aktivasyon fonksiyonları Lojistik ve Relu fonksiyonlarına göre oluşturulmuş modeller içinden en iyi değere gizli katman sayısı 2, gizli katmandaki nöron sayıları 6 - 10, Relu aktivasyon fonksiyonuna göre oluşturulan modelde ulaşıldığı belirtilmiştir. Analiz sonucunda test verileri değerlerinin YSA için %70,8 XGBoost için %75,8 ve RO için %70,2 oranında doğru tahmine ulaştığı gözlemlenmiştir. Demirel ve Hazar (2021), araştırmada 2014-2019 yılları arasındaki DOW30, DAX, FTSE100, EURO STOXX50 ve BİST 100 endekslerinin günlük verilerini almışlardır. En yüksek, en düşük ve açılış değerleri ile günlük değişim verilerinin kullanılmış olduğu ifade edilmiştir. Çalışmada ikili sınıflandırma yöntemi gerçekleştirilerek endekslerin günlük hareket yönü artmışsa 1, azalmışsa 0 olarak gösterilmiştir. Değişimin olmadığı verilerin temizlendiği ifade edilmiştir. Son durumda 5275 adet veri bulunmakta olup bu veri kümesi YSA'nın eğitimi için kullanılmıştır. BİST 100 hareket yönünü tahmin etmek için her biri 4 farklı YSA mimarisi tasarlanmış olduğu belirtilerek her bir model için 4 girdi değeri, 1 çıktı değeri bulunurken gizli katmandaki nöron sayısında değişiklikler yapıldığı ifade edilmiştir. Tasarlanan 4 modelin karmaşıklık matrisi performansı incelenmiştir. Analiz sonucunda 4 modelin eğitimden sonraki bilgileri tahmin başarısının, her biri için %50'nin üzerinde olduğu açıklanmıştır. Araştırmada YSA ile oluşturulan modeller içerisindeki en başarılı modelin performans (%), gizli katman-nöron sayıları değerlerini gösteren tabloya göre %59,57 başarı ile 1 gizli katman ve gizli katmanda 10 nöron bulunan model olduğu ifade edilmiştir. Sarı ve Saka Iğın (2022), araştırmalarında "BRICS borsa endeksleriyle BİST 100 endeksi tahmin edilebilir mi?" sorusuna YSA yöntemiyle yanıt aramışlardır. 2008 Şubat- 2019 Aralık arasındaki dönemlere ait aylık bazdaki 143 gözlem değeri kullanılmıştır. BİST 100 endeksi aylık kapanış değeri bağımlı değişken, BRICS (Brezilya,

Rusya, Hindistan, Çin ve Güney Afrika) ülkelerinin borsa kapanış değerleri ise bağımsız değişkenlerdir. Araştırmada belirlenen hipotezin test edilmesi amacıyla belirlenen değişkenlere ait 20 model test edilmiştir. Oluşturulan modellerdeki gerçekleşen verilerle tahmin değerleri arasındaki ilişkiyi açıklamak amacıyla SPSS paket programı kullanıldığı belirtilmiştir. Modeldeki verilerin %70'i eğitim %30'u test amaçlı kullanılmıştır. Çalışmada verilerin daha verimli olması amacıyla Max Kuralı ile normalleştirme, ağı eğitiminde ise bulanıklaştırma yapıldığı belirtilmiştir. Modellerin başarısı Kök Ortalama Karesel Hata (KOKH), R² ve Verimlilik Katsayısına (VK) göre değerlendirilmiş, VK değeri 0,7 ve üzeri yüksek tahmin başarısına sahip modeller olarak kabul edilmiştir. Çalışmadaki 20 modelin ilk dokuzunda VK değeri 0,70'in üzerinde değerlerdir. Sonuç olarak BİST 100 Endeksini tahmin etmede en başarılı endeksler sırasıyla Hindistan, Güney Afrika ve Rusya olurken Brezilya ve Çin ise başarısız bulunmuştur. Yazarlar, tüm bu veriler sonucunda portföy çeşitlendirmesi yapan bir yatırımcının Çin ve Brezilya borsalarına yönelmelerinin kârlılıklarını arttırabileceğini belirtmişlerdir. Özcan Akdağ, Karaatlı ve Kocabıyık (2022), BİST Ulaştırma Endeksi tahminini aylık ve günlük veriler ile YSA NARX modeli kullanarak yapmışlardır. Analiz için kullanılan günlük verilerin 19/07/2010-15/10/2021 dönemini, aylık verilerin 08/2010-08/2021 dönemini kapsadığı açıklanmıştır. Araştırma sonucunu değerlendirebilmek için Ortalama Mutlak Sapma (MAD), Ortalama Kare Hata (MSE), Ortalama Kare Hatanın Karekökü (RMSE), Ortalama Mutlak Yüzde Hata (MAPE) değerlerine bakılmış ve MAPE değerinin %10'un altında yer almasının "çok iyi" modellenmiş olduğu belirtilmiştir. Araştırma sonucunda MAPE değerleri aylık veriler için %2,6325; günlük veriler için ise %1,8452 olarak bulunmuştur. YSA NARX modeli ile yapılan çalışmada aylık ve günlük verilerle elde edilen sonuçlar karşılaştırıldığında günlük verilerin tahmin açısından daha başarılı olduğu yönünde sonuçlara ulaşılmıştır.

III. VERİ SETİ VE UYGULAMA

Bu araştırmada, Ocak 2004- Mart 2024 dönemlerine ait Euro, Dolar, Gram Altın, Brent Petrol, BİST 100 Endeksi, Tüketici Fiyat Endeksi (TÜFE), XELKT endeksine ait olmak üzere her biri 243 adet aylık verilerden oluşan 7 değişken kullanılmıştır. Çalışmada Tüketici Fiyat Endeksine ait veriler (2003=100) Türkiye İstatistik Kurumu (TÜİK) web sayfasından elde edilmiştir. Euro, Dolar, Gram Altın, Brent Petrol, BİST 100 Endeksi, XELKT Endeksi verileri ise bir veri sağlayıcı şirketi olan MATRİKS'ten alınmıştır. Kurulacak YSA modelinin eğitim ve test aşamasının daha başarılı olması sağlamak amacıyla veriler normalizasyon yapılabilir. Bu araştırmada da kullanılacak değişkenlerin doğal logaritması alınarak verilerin ön işlemesi (normalizasyonu) sağlanmıştır. Yapay Sinir Ağları analizi için ise MATLAB R2024a kullanılmıştır. Analizde Euro, Dolar, Gram Altın, Brent Petrol, BİST 100 ve TÜFE verileri bağımsız değişken; XELKT Endeksi ise bağımlı değişken olarak YSA modelleri oluşturulmuştur. Zhang, Patuwo ve Hu (1998, s. 50), analizde eğitim ve test oranı belirlenmesinde literatürde belirli bir kural olmadığını ancak yazarların çoğunlukla %90 eğitim %10 test, %80 eğitim %20 test, %70 eğitim %30 test kuralına göre seçtiklerini bazı yazarların ise kendi araştırma problemlerine göre farklı oranları seçtiklerini belirtmişlerdir. YSA oluşturulurken model seçimi, gizli katman sayısı, katmanlardaki nöron sayısı ve bunlar gibi parametrelerin seçiminde belli bir kuralın bulunmaması bu parametrelerin belirlenmesinin deneme yanılma yoluyla yapılmasını gerektirirken, eğitimin uzun zaman alabilmesi gibi dezavantaja sebep olur (Karacameydan, 2009, ss. 80-81). Araştırmada MATLAB R2024a ile ileri beslemeli (feedforward) YSA modelleri oluşturulmuştur. Eğitim fonksiyonu olarak Levenberg-Marquardt (LM), Bayesian Regularization (BR) ve Scaled Conjugate Gradient (SCG) geri yayılımlı algoritmalar kullanılmış olup; değişkenlerin logaritması alınarak normalizasyonu yapılmış ve veriler rastgele olacak şekilde hem %80 eğitim %20 test oranı hem de %90 eğitim %10 test oranına göre ayrılarak eğitilmiştir. Tablo 1'de analiz için oluşturulan YSA modellerinin bilgileri bulunmaktadır. Tüm bağımlı değişkenlerin analizinde ilgili kodlar ikinci kez çalıştırılmış ve ikinci analiz sonuçlarına göre yorumlamalar yapılmıştır. Bunun yanı sıra program, Epoch sayısı maksimum 1000, performans ölçütleri ise MAPE (Ortalama Mutlak Yüzde Hata), MSE (Ortalama Kare Hata) ve RMSE (Kök Ortalama Kare Hata) olarak

belirlenmiştir. Sonuçların yorumlanmasında Regresyon analizindeki “Toplam R” değeri ve MSE, RMSE ve MAPE değerleri kıyaslanmıştır.

TABLO 1 | Yapay Sinir Ağı Modeli ile İlgili Bilgiler

Eğitim Fonksiyonu	Gizli Katman Sayısı	Gizli Katmanlarda Yer Alan Nöron Sayısı	Birinci Gizli Katmandaki Transfer Fonksiyonu	İkinci Gizli Katmandaki Transfer Fonksiyonu	Üçüncü Gizli Katmandaki Transfer Fonksiyonu
Levenberg-Marquardt (LM)	1	5	Hiperbolik Tanjant Sigmoid (tansig)	---	---
Levenberg-Marquardt (LM)	2	5-10	Hiperbolik Tanjant Sigmoid (tansig)	Logaritmik Sigmoid (logsig)	---
Levenberg-Marquardt (LM)	3	5-10-15	Hiperbolik Tanjant Sigmoid (tansig)	Logaritmik Sigmoid (logsig)	Doğrusal Transfer Fonksiyonu (Purelin)
Bayesian Regularization (BR)	1	5	Hiperbolik Tanjant Sigmoid (tansig)	---	---
Bayesian Regularization (BR)	2	5-10	Hiperbolik Tanjant Sigmoid (tansig)	Logaritmik Sigmoid (logsig)	---
Bayesian Regularization (BR)	3	5-10-15	Hiperbolik Tanjant Sigmoid (tansig)	Logaritmik Sigmoid (logsig)	Doğrusal Transfer Fonksiyonu (Purelin)
Scaled Conjugate Gradient (SCG)	1	5	Hiperbolik Tanjant Sigmoid (tansig)	---	---
Scaled Conjugate Gradient (SCG)	2	5-10	Hiperbolik Tanjant Sigmoid (tansig)	Logaritmik Sigmoid (logsig)	---
Scaled Conjugate Gradient (SCG)	3	5-10-15	Hiperbolik Tanjant Sigmoid (tansig)	Logaritmik Sigmoid (logsig)	Doğrusal Transfer Fonksiyonu (Purelin)

Zhang vd. (1998, s. 51), MSE, MAPE ve RMSE değerlerine ait denklemleri şu şekilde göstermektedir:

$$\bullet \text{Ortalama Kare Hata} \quad (MSE) = \frac{\sum (e_i)^2}{N} \quad (1)$$

$$\bullet \text{Karekök Ortalama Hata Kareler} \quad (RMSE) = \sqrt{MSE} \quad (2)$$

$$\bullet \text{Ortalama Mutlak Yüzde Hata} \quad (MAPE) = \frac{1}{N} \sum \left| \frac{e_i}{y_i} \right| (100) \quad (3)$$

Denklemlerde yer alan e_i tahmin hatasını, y_i gerçek değeri, N ise hata terimleri sayısını göstermektedir:

MSE değeri çıktı değerleri ve hedef değerler arasındaki ortalama kare farkını ifade ederken MSE'nin düşük değer olması daha başarılı olduğunu, sıfır olması durumu ise hata olmadığını anlatmaktadır (Özcan Akdağ vd., 2022, s. 2739). Bu sebeple MSE değeri sıfıra yakın oldukça hatanın daha az olduğu söylenebilir. Böylece MSE değeri en küçük olan model daha başarılıdır. MSE değerinin karekökü alındığında RMSE değerine ulaşılmaktadır. Yukarıdaki denklemlerde hesaplanan MSE, RMSE ve MAPE değerleri, gerçekte gözlemlenen değerler ile analiz sonucu ulaşılan tahmin değerleri arasındaki hata oranını gösterdiği için MSE, MAPE ve RMSE değerlerinin düşük olması hatanın az olduğunu göstermektedir. Karakul, (2020, s. 507) “Lewis (1982) MAPE değerinin %10'un altında olan modellerin tahmin performansını “çok iyi” olarak değerlendirmektedir” açıklamasını yapmıştır. Özcan Akdağ vd. (2022, s. 2734) analiz sonucu ulaşılan çıktı değerleri ve hedef değerler arasındaki ilişkiyi değerlendirmek amacıyla test, eğitim ve doğrulama için doğrusal regresyon analizinin yapıldığını açıklamışlardır. Buna göre R değerinin 1'e yakın olması analizin başarılı olduğunu göstermektedir.

Bu bilgilere göre analiz sonucu değerlendirme yaparken RMSE, MAPE ve MSE değeri en düşük, Toplam R değeri en yüksek model bulunmaya çalışılacaktır.

IV. ANALİZ SONUÇLARI

XELKT Endeksi için %80 eğitim ve %20 test oranına göre yapılan tahmin sonuçları Tablo 2'de gösterilmiştir. Tablo 2'ye göre, 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.9955, “MSE” değeri 0.0064, “MAPE” değeri 1.7982, “RMSE” değeri 0.0797 ile ulaşmıştır. Yine Tablo 2'ye göre Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde ise 0.99863 “Toplam R”, MSE değeri 0.0026, MAPE değeri 0.9361 ve RMSE değeri 0.0513 ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.99779 “Toplam R”, MSE değeri 0.0032, MAPE değeri 1.0780 ve RMSE değeri 0.0562 ile Bayesian Regularization fonksiyonu başarılı olmuştur. XELKT Endeksine ait normalizasyonu yapılmış verilerle oluşturulan ve Tablo 2'de gösterilen tüm modeller içinde en başarılı model 2 gizli katmanlı modeller içinde yer alan 0.99863 Toplam R, 0.0026 MSE değeri, MAPE değeri 0.9361 ve RMSE değeri 0.0513 ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir.

TABLO 2 | XELKT Endeksi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri	MAPE	RMSE
Levenberg-Marquardt	5	0.98535	0.98991	0.9498	0.98409	0.0245	3.3538	0.1564
Bayesian Regularization	5	0.9959	---	0.99404	0.9955	0.0064	1.7982	0.0797
Scaled Conjugate Gradient	5	0.95445	0.97795	0.97021	0.96106	0.0546	5.2691	0.2336
Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri	MAPE	RMSE
Levenberg-Marquardt	5-10	0.99753	0.99263	0.99469	0.99616	0.0056	1.4124	0.0747
Bayesian Regularization	5-10	0.99918	---	0.99648	0.99863	0.0026	0.9361	0.0513
Scaled Conjugate Gradient	5-10	0.95703	0.98265	0.96894	0.96633	0.0469	4.9069	0.2165
Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri	MAPE	RMSE
Levenberg-Marquardt	5-10-15	0.99097	0.96021	0.98391	0.98698	0.0185	2.8668	0.1362
Bayesian Regularization	5-10-15	0.99889	---	0.99372	0.99779	0.0032	1.0780	0.0562
Scaled Conjugate Gradient	5-10-15	0.94071	0.91369	0.97624	0.95046	0.0710	5.7756	0.2665

Tablo 3'de ise XELKT Endeksi için %90 eğitim ve %10 test oranına göre yapılan analiz sonuçlarını incelediğimizde 5 nöron bulunan 1 gizli katmanlı modeller içinde en iyi sonuca Bayesian Regularization fonksiyonu ile oluşturulan model “Toplam R” değeri 0.9969, MSE değeri 0.0044, MAPE değeri 1.4469 ve RMSE değeri 0.0662 ile ulaşmıştır. Nöron sayısı ilk katmanda 5, ikinci katmanda 10 olarak belirlenen 2 gizli katmanlı modeller içinde 0.999 “Toplam R”, MSE değeri 0.0014, MAPE değeri 0.7773, RMSE değeri 0.0376 ile Bayesian Regularization fonksiyonu; Nöron sayıları 5-10-15 olan 3 gizli katmanlı modellerden ise 0.9984 “Toplam R”, MSE değeri 0.0023, MAPE değeri 1.0103 ve RMSE değeri 0.0475 ile Bayesian Regularization fonksiyonu başarılı olmuştur. XELKT Endeksine ait normalizasyonu yapılmış verilerle oluşturulan ve Tablo 3'de gösterilen tüm modeller içinde en başarılı model 2 gizli katmanlı modeller içinde yer alan 0.999 “Toplam R”, MSE değeri 0.0014, MAPE değeri 0.7773, RMSE değeri 0.0376 ile Bayesian Regularization fonksiyonu ile oluşturulan modeldir

TABLO 3 | XELKT Endeksi Analiz Sonucu

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri	MAPE	RMSE
Levenberg-Marquardt	5	0.99477	0.99498	0.99014	0.99427	0.0082	1.8150	0.0904
Bayesian Regularization	5	0.99715	---	0.99499	0.9969	0.0044	1.4469	0.0662
Scaled Conjugate Gradient	5	0.9643	0.93788	0.95496	0.9608	0.0548	5.3254	0.2342

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri	MAPE	RMSE
Levenberg-Marquardt	5-10	0.99741	0.99263	0.98816	0.99678	0.0045	1.5213	0.0674
Bayesian Regularization	5-10	0.99921	---	0.99144	0.999	0.0014	0.7773	0.0376
Scaled Conjugate Gradient	5-10	0.96598	0.96484	0.97438	0.96774	0.0449	4.6110	0.2119

Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Eğitim Değeri (R)	Doğrulama Değeri (R)	Test Değeri (R)	Toplam (R)	MSE Değeri	MAPE	RMSE
Levenberg-Marquardt	5-10-15	0.98714	0.98601	0.97442	0.98627	0.0193	2.9796	0.1389
Bayesian Regularization	5-10-15	0.9986	---	0.99511	0.9984	0.0023	1.0103	0.0475
Scaled Conjugate Gradient	5-10-15	0.94556	0.97999	0.82856	0.95026	0.0717	5.5156	0.2678

Yukarıda tahmin edilen modellerden %80 Eğitim ve %20 Test oranı ile %90 Eğitim ve %10 Test Oranına göre en başarılı modellere ait sonuçları Tablo 4'te gösterilmiştir. Buradan XELKT Endeksi için en iyi sonuç veren modelin %90 Eğitim %10 Test Oranı ile 1. Gizli katmanında 5 nöron 2. Gizli katmanında 10 nöron bulunan 2 gizli katmandan oluşan Bayesian Regularization eğitim fonksiyonu ile tahmin edilen model olduğu sonucuna varmak mümkündür.

TABLO 4 | En İyi Tahmin Başarısına Sahip Modellerin Karşılaştırılması


%80 EĞİTİM %20 TEST

HİSSE SENEDİ	Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Toplam "R"	MSE	MAPE	RMSE
BİST ELEKTRİK	Bayesian Regularization	5-10	0.99863	0.0026	0.9361	0.0513


%90 EĞİTİM %10 TEST

HİSSE SENEDİ	Eğitim Fonksiyonu	Gizli Katman-Nöron Sayısı	Toplam "R"	MSE	MAPE	RMSE
BİST ELEKTRİK	Bayesian Regularization	5-10	0.999	0.0014	0.7773	0.0376


XELKT Endeksi'ne ait en iyi tahmin sonuca sahip modelin grafiklerle gösterimi aşağıda yer almaktadır.

ŞEKİL 4 | XELKT Endeksi Yapay Sinir Ağı Yapısı

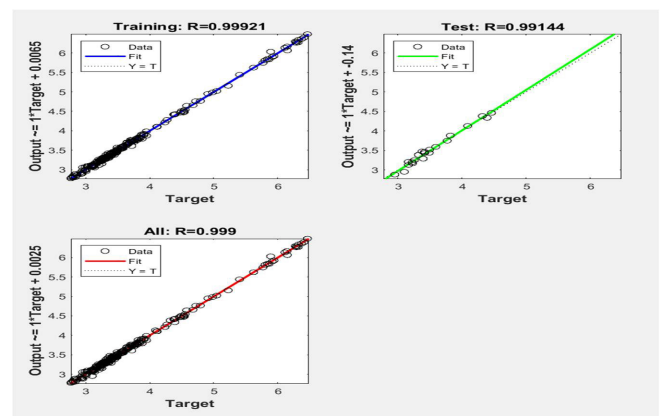
XELKT Endeksi için Matlab'da oluşturulan sinir ağı modelinde Şekil 4'de görüldüğü üzere 6 girdi değişkeni 1 çıktı değişkeni seçilmiştir. İlk gizli katmanda 5 nöron, ikincisinde 10 nöron bulunan ve ilk gizli katmanda Hiperbolik Tanjant Sigmoid transfer fonksiyonu ikinci gizli katmanda Logaritmik Sigmoid transfer fonksiyonu kullanılmıştır.

GRAFİK 1 | XELKT Endeksi Performans Grafiği

Grafik 1'de XELKT Endeksi Performansı Grafiği yer almaktadır. En iyi eğitim performansı değeri 1000. döngüde 0.0011934 olarak ifade edilmiştir. 1000. döngü gerçekleşikten sonra eğitim durmuştur.

GRAFİK 2 | XELKT Endeksi Hata Histogram Grafiği

Hata histogram grafiği hedeflenen değerler ile analiz sonucunda ulaşılan değerler arasındaki farkın yani hataların dağılımını göstermektedir. Bu nedenle bazı değerler negatiftir. Bu grafikte mavi renkteki sütunlar eğitim verilerini, kırmızı sütunlar ise test verilerini temsil etmektedir. Turuncu çizgi ise sıfır hata noktasını ifade etmektedir. Grafik 2'de hata dağılımının çoğunlukla -0.1071 ve 0.1115 aralığında olduğu görülmektedir.

GRAFİK 3 | XELKT Endeksi Regresyon Grafiği

Grafik 3 tahmin edilen en başarılı modelin; eğitim verisi, test verisi ve her ikisini de kapsayan, bu çalışmada “Toplam R” olarak belirtilen veri grupları üzerindeki başarısını ölçmektedir. Burada dikey eksen ulaşılan değerleri, yatay eksen ise hedeflenen değerleri ifade etmektedir. Hedeflenen değer ve ulaşılan değer arasında iyi bir uyum olduğunu söyleyebilmek için diğer renkli çizgilerin $Y=T$ ile ifade edilen 45 derecelik kesikli çizginin üzerinde veya bu çizgiye yakın olması gerekir. Aynı zamanda bu durum R ile ifade edilen sayısal değer 1 veya 1'e yakın olması demektir. XELKT Endeksi'nin regresyon grafiğine baktığımızda Eğitim R, Test R ve Toplam R değerlerinin 0.99'un üzerinde olduğu görülmektedir. Bu sonuç hedeflenen değer ve ulaşılan değer arasında iyi bir uyum olduğunu, MSE, MAPE ve RMSE değerleri de göz önünde bulundurulduğunda tahmin edilen yapay sinir ağı modelinin başarılı olduğunu göstermektedir.

SONUÇ

Çalışmada Dolar, Euro, Gram Altın, Brent Petrol, TÜFE ve BİST 100 Endeksi verilerinin XELKT Endeksi hisse senedinin fiyat tahminindeki etkisi incelenmiştir. Bunun için Yapay Sinir Ağları Yöntemi kullanılmıştır. Microsoft Office Excel ve MATLAB R2024a programları yardımıyla analiz yapılmıştır. Dolar, Euro, Gram Altın, Brent Petrol, TÜFE ve BİST 100 Endeksi verileri bağımsız değişkenler; XELKT Endeksi verileri ise bağımlı değişken olarak belirlenmiştir.

Farklı eğitim fonksiyonlarının kullanılması, gizli katman ve bu katmanlardaki nöron sayılarının değiştirilerek analiz yapılması, analizde kullanılacak verilerin eğitim ve test oranlarının değiştirilmesi gibi durumlar göz önüne alındığında toplamda 18 analiz yapılmıştır. Hem %80 eğitim %20 test oranı hem de %90 eğitim %10 test oranına göre belirlenen modellerin ikisinde de Bayesian Regularization eğitim fonksiyonu, iki gizli katman ve gizli katmanlarında sırasıyla 5 ve 10 nöron bulunan modeller daha başarılıdır. Ancak iki model kıyaslandığında %90 eğitim %10 test oranı kullanılarak Bayesian Regularization eğitim fonksiyonu ile çok katmanlı YSA modeli oluşturularak daha başarılı sonuçlar elde ettiği gözlemlenmiştir. Yapılan tüm analizler incelendiğinde çalışmada kullanılan Scaled Conjugate Gradient eğitim fonksiyonu ile oluşturulan tüm modellerin kategorilerindeki diğer eğitim fonksiyonlarına göre daha az başarılı olduğu ifade edilebilir. Çınaroğlu ve Avcı (2020) çalışmalarında Levenberg- Marquardt ve Bayesian Regularization eğitim fonksiyonlarını karşılaştırmış ve Bayesian Regularization eğitim fonksiyonunun daha başarılı olduğunu belirtmişlerdir. Yıldız (2006)'da yaptığı çalışmada döviz kuru tahmini için içerisinde Levenberg- Marquardt (LM), Bayesian Regularization (BR) ve Ölçekli Eşlenik Gradyan (SCG) bulunan 12 farklı eğitim algoritmasından Bayesian Regularization fonksiyonunun başarılı olduğunu ifade etmiştir. İlerideki çalışmalarda faiz oranı, para arzı, sanayi üretim endeksi veya üretici fiyat endeksi verileri ya da firmaların fiyat/ kazanç oranı, piyasa değeri/ defter değeri oranı, özsermaye kârlılığı gibi verileri de analiz değişkenlerine eklenerek XELKT Endeksi fiyat tahmini yapılabilir. Yine farklı endeksler için bu bağımsız değişkenler ve yapay sinir ağı modelleri kullanılarak fiyat öngörüsü yapılabilir. Değişkenlere ait verilerin bulunabilmesi durumunda 20 yıldan daha uzun dönemler için yöntemin başarısı incelenebilir. Farklı YSA modellerinde veya modeli etkileyen parametrelerde de değişiklikler yapılarak farklı çalışmalarla literatüre katkı sağlanabilir.

KAYNAKÇA

- [1] Asilkan, Ö., & İrmak, S. (2009). İkinci el otomobillerin gelecekteki fiyatlarının yapay sinir ağları ile tahmin edilmesi. *Stileyman Demirel Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 14(2), 375-391.
- [2] Aydın, Ö. F. (2019). Yapay sinir ağları ile enflasyon tahmini (Yüksek Lisans Tezi). Beykent Üniversitesi Fen Bilimleri Enstitüsü.
- [3] Chen, A. S., Leung, M. T., & Daouk, H. (2003). Application of neural networks to an emerging financial market: forecasting and trading the Taiwan Stock Index. *Computers & Operations Research*, 30, 901-923.
- [4] Çalışkan, M. M. T., & Deniz, D. (2015). Yapay sinir ağlarıyla hisse senedi fiyatları ve yönlerinin tahmini. *Eskişehir Osmangazi Üniversitesi İİBF Dergisi*, 10(3), 177-194.
- [5] Çanakçı, A. (2006). Yapay sinir ağlarının makroekonomik bir model üzerine uygulanması: bir Türkiye örneği (Yüksek Lisans Tezi). Gazi Üniversitesi Sosyal Bilimler Enstitüsü.

- [6] Çınaroğlu, E., & Avcı, T. (2020). THY hisse senedi değerinin yapay sinir ağları ile kestirimi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi* 34(1), 1-19. <https://doi.org/10.16951/atauniibd.530322>
- [7] Demirel, A. C., & Hazar, A. (2021). Borsa endekslerinin birbirleriyle etkileşimi ve endeks yönünün tahmini: BİST100 üzerine bir uygulama. *Ekonomi ve Finansal Araştırmalar Dergisi*, 3(1), 1-8.
- [8] Elmas, Ç. (2021). *Yapay zeka uygulamaları* (5. Baskı). Ankara: Seçkin Yayıncılık.
- [9] Hamzaçebi, C. (2021). *Matlab uygulamalı yapay sinir ağları* (2. Baskı). Ankara: Seçkin Yayıncılık.
- [10] Karacameydan, F. (2009). Yatırım fonları net varlık değerlerinin yapay sinir ağları yöntemiyle tahmin edilmesi (Yüksek Lisans Tezi). Bozok Üniversitesi Sosyal Bilimler Enstitüsü.
- [11] Karakul, A. K. (2020). Yapay sinir ağları ile BİST-100 endeks değerinin tahmin edilmesi. *Mehmet Akif Ersoy Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7(2), 497-509. <https://doi.org/10.30798/makuiibf.721866>
- [12] Koç Ustalı, N., Tosun, N., & Tosun, Ö. (2021). Makine öğrenmesi teknikleri ile hisse senedi fiyat tahmini. Eskişehir Osmangazi Üniversitesi İİBF Dergisi, 16(1), 1-16. <https://doi.org/10.17153/oguibf.636017>
- [13] Korkut, D. (2019). Yapay sinir ağları yöntemi ile talep tahmini ve ayakkabı sektörüne uygulanması (Yüksek Lisans Tezi). Ankara Hacı Bayram Veli Üniversitesi Lisansüstü Eğitim Enstitüsü.
- [14] Özalp, A., & Anagün, A. S. (2003). Yapay sinir ağı performansına etki eden faktörlerin analizinde taguchi yöntemi: hisse senedi fiyat tahmini uygulaması. *İstatistik Araştırma Dergisi*, 2(1), 29-45.
- [15] Özcan Akdağ, N., Karaatlı, M., & Kocacıyık, T. (2022). BİST Ulaştırma endeksinin YSA NARX modeli ile öngörülmesi. *Alanya Akademik Bakış*, 6(3), 2721-2746. <https://doi.org/10.29023/alanyaakademik.1088404>
- [16] Sarı, S. S., & Saka İlgün, K. (2022). BİST-100 endeks hareketlerinin BRICS endeksleri aracılığıyla tahmin edilmesi: yapay sinir ağları uygulaması. *Abant Sosyal Bilimler Dergisi*, 22(1), 350-366. <https://doi.org/10.11616/asbi.1096346>
- [17] Sarıkaya, G. (2019). Yapay sinir ağları ve regresyon modelleri ile BİST Ulusal-100 endeksinin tahmini. *21. Yüzyılda Eğitim ve Toplum*, 8(23), 325-340.
- [18] Tektaş, A., & Karataş, A. (2004). Yapay sinir ağları ve finans alanına uygulanması: hisse senedi fiyat tahminlemesi. *Atatürk Üniversitesi İktisadi ve İdari Bilimler Dergisi*, 18(3-4), 337-349.
- [19] Türkiye İstatistik Kurumu. (2020, Eylül 16). Erişim adresi: <https://data.tuik.gov.tr>
- [20] Türkiye İstatistik Kurumu (2024, Nisan 26). Erişim adresi: <https://data.tuik.gov.tr>
- [21] Vural, B. B. (2007). Yapay sinir ağları ile finansal tahmin (Yüksek Lisans Tezi). Ankara Üniversitesi Sosyal Bilimler Enstitüsü.
- [22] Yanık, E. (2019). İş makineleri sektöründe yapay sinir ağları ile talep tahmini uygulaması (Yüksek Lisans Tezi). Kırıkkale Üniversitesi Fen Bilimleri Enstitüsü.
- [23] Yavuz, S. (2006). Performans artırmaya yönelik paralel mimarilerin yapay sinir ağları yaklaşımı ile değerlendirilmesi (Doktora Tezi). Yıldız Teknik Üniversitesi Fen Bilimleri Enstitüsü.
- [24] Yıldız, Ö. (2006). Döviz kuru tahmininde yapay sinir ağlarının kullanımı (Yüksek Lisans Tezi). Eskişehir Osmangazi Üniversitesi Sosyal Bilimler Enstitüsü.
- [25] Yiğiter, Ş. Y., Sarı, S. S., & Başakın, E. E. (2017). Hisse senedi kapanış fiyatlarının yapay sinir ağları ve bulanık mantık çıkarım sistemleri ile tahmin edilmesi. *Kahramanmaraş Sütcü İmam Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, 7(1), 1-22.
- [26] Yurtoğlu, H. (2005). Yapay sinir ağları metodolojisi ile öngörü modellemesi: bazı makroekonomik değişkenler için Türkiye örneği (Uzmanlık Tezi), Devlet Planlama Teşkilatı. DPT Yayın No: 2683.
- [27] Yüksel, R., & Akkoç, S. (2016). Altın fiyatlarının yapay sinir ağları ile tahmini ve bir uygulama. *Doğuş Üniversitesi Dergisi*, 17(1), 39-50.
- [28] Zhang, G., Patuwo, B. E. & Hu, M.Y. (1998). Forecasting with artificial neural networks: The state of the art, *International Journal of Forecasting*, 14, 35–62.

A RESEARCH ON BIST ELECTRICITY INDEX PRICE FORECASTING WITH ARTIFICIAL NEURAL NETWORKS

EXTENDED ABSTRACT

1. INTRODUCTION

While some investors prefer to take less risk, others may prefer to take more risk. Stocks, on the other hand, are investment instruments that carry more risk than fixed-income financial instruments such as government bonds and treasury bills, but offer higher potential returns and attract more attention from investors every day. On the other hand, the high risk of equities and the uncertainty about the future can make investors confused about which financial instrument to choose. Therefore, the ability of investors to predict the returns of their chosen stock will help them decide whether or not to invest in that stock. It is

an important advantage for investors to know in advance whether they will make a profit or a loss on their investments, so that they can decide whether or not to invest. There are studies in the literature that show that stock price predictions are made through the analysis of artificial neural networks and that artificial neural networks are successful in making price predictions. Artificial neural networks can be defined as systems that have been created using the functioning of the human brain as a model, adapting qualities such as memory, decision-making and learning to machines.

industrial production index or producer price index data or firms' price/earnings ratio, market value/book value ratio, equity profitability data to the analysis variables. Again, price estimation can be made using these independent variables and artificial neural network models for different indexes. At the same time, if the data of the variables can be found, the success of the method can be examined for periods longer than 20 years. In addition, different studies can be presented to the literature by making changes in different ANN models or parameters affecting the model.

2. MATERIALS AND METHODS

In this study, BIST ELECTRICITY (XELKT) Index stock price prediction was made. Artificial neural network models were created using monthly data for the periods January 2004 - March 2024. The data were normalized by taking the logarithm. Microsoft Excel and MATLAB R2024a were used in the study. In the study, data on consumer price index figures (2003=100) for January 2004-August 2020 were taken on the Turkish Statistical Institute (TUIK) website (<https://data.tuik.gov.tr>) on 16.09.2020; The necessary data for the periods September 2020-March 2024 were accessed through TUIK's website on 26.04.2024. Euro, Dollar, Gram of Gold, Brent Oil, BIST 100 Index, XELKT Index data were obtained from MATRIKS, a data provider company, on 26.04.2024. Within the scope of the analysis, XELKT Index is the dependent variable; Euro, Dollar, Gram Gold, Brent Oil, Consumer Price Index and BIST100 data were determined as independent variables. In the analysis, it was tried to determine the effects of different training and testing rates, different training functions, the number of hidden layers and the change in the number of neurons in these layers on the analysis. For this purpose, 18 different analyzes were carried out according to the rates of 80% training, 20% test and 90% training and 10% test, with one hidden layer, two hidden layers and three hidden layers, with Levenberg-Marquardt, Bayesian Regularization and Scaled Conjugate Gradient training functions. Mean Squared Error (MSE), Mean Absolute Percentage Error (MAPE) and Root Mean Square Error (RMSE) rate was determined as the performance evaluation criterion of the analyses. For the analysis can be counted successful, it is important that the MSE, MAPE and RMSE values are quite small. On the other hand, the Total R value shows the relationship between the analysis result reached by the model and the targeted result. An R value close to 1 indicates that the result achieved is close to the targeted result. For this reason, when comparing the analysis results, the model with the smallest MSE, MAPE and RMSE values and R value closest to 1 was tried to be selected.

3. RESULTS AND DISCUSSION

As a result of the analysis, the most successful model among the models created with an 80% training and 20% testing rate was the Bayesian Regularization training function, which had 2 hidden layers and 5 and 10 neurons in these layers, respectively. In the model, a total R value of 0.99863, MSE value of 0.0026, MAPE value of 0.9361 and RMSE value of 0.0513 were reached. Among the models created with a 90% training and 10% testing rate, the most successful was the Bayesian Regularization training function, which had 2 hidden layers and 5 and 10 neurons in these layers, respectively. In the model, a total R of 0.999, MSE value of 0.0014, MAPE value of 0.7773 and RMSE value of 0.0376 were reached. Among these two models, the most successful one was the Bayesian Regularization training function, which was created with 90% training and 10% testing rate, with 2 hidden layers and 5 and 10 neurons in the layers, respectively. In this study, Scaled Conjugate Gradient training function is less successful than other training functions. Çınaroğlu and Avcı (2020) compared the Levenberg-Marquardt and Bayesian Regularization training functions in their study and explained that the Bayesian Regularization training function was more successful. Yıldız (2006) also explained that the Bayesian Regularization function was successful among 12 different training algorithms including Levenberg-Marquardt (LM), Bayesian Regularization (BR) and Scaled Conjugate Gradient (SCG) for exchange rate prediction. In future studies, BIST Electricity Index price estimation can be made by adding interest rate, money supply,