



Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi
Kastamonu University Journal of Faculty of Economics and
Administrative Sciences

Aralık 2023 Cilt: 25 Sayı:2
iibfdergi@kastamonu.edu.tr

Başvuru Tarihi / Received: 09.03.2023
Kabul Tarihi / Accepted: 06.12.2023
DOI: 10.21180/iibfdkastamonu.1262407

Garch ve Yapay Sinir Ağları Modelleri Yardımıyla Volatilite Tahmini: Türk Borsası Örneği

Cumhur ŞAHİN¹

Öz

Küreselleşme olgusunun 1990'lı yıllarla birlikte baskın hale gelmesiyle birlikte uluslararası ekonomik düzende ülkelerin birbiriyle etkileşim ve entegrasyonunun çarpıcı bir biçimde artmıştır. Bu da iktisadi bağların kuvvetlenmesi, finansal piyasalarda yaşanan hızlı değişimler, pazarlar arasındaki ilişkilerin ve risklerin artmasına yol açmaktadır. Finansal piyasalar hali hazırda ortaya çıkan gelişmelere karşı çok daha hassas hale gelmektedir. Finansla ilgili akademik araştırmalarda özellikle finansal zaman serileri ve bunların öngörüsüne yönelik çalışmalar oldukça önemli bir yer tutmaktadır. Dalgalanma veya oynaklık olarak da ifade edilebilen volatilite kavramı finansal piyasalarda vazgeçilmez bir yere sahiptir. Bundan dolayı, volatilitenin en yüksek duyarlılıkla tahmin edilmesi son derece yararlıdır. Son yıllarda finansal endekslerin oynaklığını tahmin etmek için GARCH (Generalized Autoregressive Conditional Heteroskedasticity-Genelleştirilmiş Otoregresif Koşullu Değişen Varyans) tipi modellerin yanı sıra ANN (Artificial Neural Network-yapay sinir ağları) modelleri de yaygın olarak kullanılmaktadır. Bu araştırmanın amacı, farklı model türlerinin birleştirilmesinin menkul kıymet borsa endeksi volatilitesi tahminlerini iyileştirip iyileştiremeyeceğine karar verilmesidir. Bu nedenle, BIST-100 Endeksi volatilitesini tahmin etme yetenekleri açısından iki hibrit model kullanılarak, Asimetrik GARCH modeli ve bir yapay sinir ağı modeli karşılaştırılmıştır. Sonuçlar, bir EGARCH modeli tarafından elde edilen şartlı volatilite tahminlerinin yanı sıra, getirileri ve tarihsel değerleri girdi olarak kabul eden bir yapay sinir ağına dayanan hibrit modelin en iyi tahmin gücünü sağladığını ortaya koymaktadır. Ayrıca, bu hibrit modelin baskınlığı, tahminin geri kalan modelleri de kapsayacak şekilde olmasıdır. Son olarak, Türk borsasında önemli kaldrac etkileri bulunduğu gösterilmiştir.

Anahtar Kelimeler: *Yapay Sinir Ağı, GARCH Modelleri, Volatilite Tahmini*

Jel Kodu: C22, C45, G10

Forecasting Volatility with Garch and Artificial Neural Networks: Evidence from Turkish Stock Exchange

Abstract

After the popularity of the globalization concept in the 1990s, increases in the interaction and integration of countries with each other, economic relationships and financial innovations resulted in high risks and linkages between markets. Financial markets have become more sensitive to new developments. Financial time series and time series forecasting have importance in the finance literature. Volatility, which can be defined as fluctuations and variance, is crucial for financial markets. Thus, forecasting volatility with sensitivity is beneficial. Recently, GARCH (Generalized Auto-Regressive Conditional Heteroscedasticity) Models and ANN (Artificial Neural Network) models have been commonly employed in order to forecast the volatility of financial indexes. The aim of this research is to decide whether combining different types of models can improve the predictions about the volatility of the stock exchange index or not. Therefore, by using two hybrid models in terms of their ability to predict BIST-100 Index volatility, the asymmetric GARCH model and an artificial neural network model had been compared. The results have revealed that besides conditional volatility predictions obtained by an EGARCH model, the hybrid model based on an artificial neural network that considers returns and historical values as inputs provides the best prediction power. Moreover, the dominance of this hybrid model is that its prediction covers the remaining models. Finally, it has been shown that there have been significant leverage effects in the Turkish stock market.

Keywords: *Artificial Neural Network, GARCH Models, Volatility Forecast*

Jel Codes: C22, C45, G10

¹ Sorumlu Yazar/Corresponding Author: Doç. Dr., Bilecik Şeyh Edebali Üniversitesi, Bozüyük Meslek Yüksekokulu, Finans, Bankacılık ve Sigortacılık Bölümü, Bilecik, Türkiye. E-posta: cumhur.sahin@bilecik.edu.tr Orcid no: 0000-0002-8790-5851

Atıf/Citation: Şahin, C. (2023), Garch ve Yapay Sinir Ağları Modelleri Yardımıyla Volatilite Tahmini: Türk Borsası Örneği, Kastamonu Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi, 25/2, s. 572-595.

Extended Abstract

Introduction

The purpose of the present study was to decide whether combining different types of models can improve stock market index volatility predictions. Weekly time series data from January 3, 2000, to December 26, 2022, were used in the study, with 1194 observations for the predictions in the training set. The dataset consisted of the weekly prices of the BIST-100 Stock Market Index, which represented the Turkish Stock Market. In the study, weekly data were used since they are less noisy. Estimating volatility, which is defined as unpredictable sudden fluctuations in financial markets, plays an important role for decision-makers in investment decision-making, policy-making, and risk management. Modeling and estimating the volatility in stocks and stock market index values, which is one of the riskiest, and for this reason, the most volatile instruments in financial markets have great importance because it affects investment and policy decisions by interacting with other macroeconomic variables. In our present day, studies that deal with financial parameter data with high volatility require the use of nonlinear conditional variable variance econometric models rather than linear time series models, which are considered among the traditional methods.

Method

Many parameters must be estimated for the estimation of the model because the lag values go way back in the studies conducted on the ARCH Model. To eliminate the drawback at this point, the Generalized Autoregressive Conditional Variance (GARCH) Model was created by Bollerslev in 1986, which takes into account the mean of the squares of the error values of the past data as the deficiency of the ARCH Model. Although traditional models are built only on the Fixed Variance Model, the GARCH Model yields healthier results when the squares of the constant variance, conditional variance, and error terms are included. In recent years, GARCH (Generalized Autoregressive Conditional Heteroskedasticity-Generalized Autoregressive Conditional Varying Variance) models as well as ANN (Artificial Neural Network) models are used widely to predict the volatility of financial indices. ANN (Artificial Neural Networks) is a computational model that attempts to emulate the ability of the human brain to process data and extract patterns. Depending on the structure of the human brain, some neurons are interconnected and organized in layers, which are classified as input layers, hidden layers, and output layers. Hybrid models are a problem-solving method that enables the use of multiple learning methods such as mathematical, statistical, econometric, or Artificial Neural Networks and different models together. A hybrid approach with modeling capability is used for the solution of both linear and nonlinear problems because of the difficulty of having complete knowledge of the properties of the data. Hybrid model structures, which are employed to overcome model limitations and increase prediction accuracy, allow the use of different perspectives in problem-solving. The diversity among the different models allows hybrid models to achieve more successful results. For this reason, two hybrid models (Asymmetric GARCH Model and an Artificial Neural Network Model) were compared in terms of their ability to predict BIST-100 Index volatility. In the study, modeling and estimation of the volatility of the BIST-100 Index, which represented the Turkish stock market, was investigated. Firstly, the ARMA Model (2, 2) was created to avert the autocorrelation by using the Box-Jenkins Methodology. Then, the two asymmetric GARCH models were constructed and compared based on predefined criteria bases.

Result and Discussion

The EGARCH Model (1, 1) with GED distributed errors was found to be the most appropriate model as Akaike, Schwarz and Hannan-Quinn Criteria had the lowest values and Log-Probability had the highest value. To increase the predictive ability of the model, two hybrid models were established using Artificial Neural Networks. The Hybrid 1 Model is a neural network that has inputs other than returns and lagged values. Also, the Hybrid 2 Model is an EGARCH Model developed by incorporating neural network output with only lagged returns as an input in the equation of variance. The contributions of the present study to the literature are as follows. Firstly, as the time horizon increases, the Hybrid 1 Model yields more precise results in in-sample and out-of-sample volatility estimates when compared to other models. Also, the use of a combination of GARCH-type models and Artificial Neural Network models in exchanges with high volatility, such as the Turkish Stock Market will be beneficial for the actors in these markets to make more accurate predictions. In this way, the stakeholders in the financial markets will have the opportunity to minimize their losses and even gain a profit with the help of an invaluable piece of knowledge, especially in terms of risk management. Also, regarding the investigation of the leverage effect of the Turkish Stock Market Index, it was observed that the fluctuation of the stock prices in the Turkish Stock Market has asymmetric effects on the volatility of the Stock Market Index.

GİRİŞ

Hisse senedi piyasası volatilitésinin modellenmesi ve tahmini, varlık ve opsiyon fiyatlamasından risk ölçümüne kadar çeşitli finansal çıkarımlar için en önemli girdilerden birisi olduğu için, araştırmacılar ve finansal piyasa katılımcıları arasında büyük bir ilgi kaynağı olmuştur. Volatilité, finansal endeksler açısından, bir risk ölçütü olarak kabul edilebilir veya bir hisse senedi fiyatının ortalama değeri etrafındaki dalgalanma derecesi olarak düşünülebilir. Finansal piyasalardaki yatırım kararları için, varlıkların getirilerinin ve volatilitésinin daha doğru tahmin edilmesi, kritik bir öneme sahiptir. Piyasa katılımcıları, finansal değişkenlerin volatilitésinin tahmin edilmesi için farklı yaklaşımlar kullanmaktadırlar.

Nazarian ve arkadaşlarına göre (2013), bu yaklaşımlar klasik ağlar ve sinir ağları olmak üzere iki kategoriye ayrılmaktadır. Klasik yöntemlerden biri, çok fazla ilgi gören, zamanla-değişen varyanslı finansal veriler hakkındaki zaman serisi modellemesidir. Engle (1982) bu tür modelleri (ARCH) ilk tanıtan kişi olurken, Bollerslev (1986) bu modelleri geliştirerek GARCH modelini oluşturmuştur. Finansal veriler oldukça değişken olduğundan, değişen varyans hatalarına - heteroskedastik hatalara - sahip olan bu modeller, finasta yaygın olarak kullanılmaktadır. (Ahmed & Suliman, 2011:114; Awartani & Corradi, 2005:167; Curto vd., 2009:311; Engle & Patton, 2007:47; Koopman vd., 2005:445; Liu & Hung, 2010:4928; Lu & Perron, 2010:138; Marcucci, 2005:6).

Bununla birlikte, çeşitli değişkenleri tahmin etmedeki başarılarına rağmen, klasik yöntemlerin (yapısal modeller) tarihsel olaylardan elde edilen bilgilere dayanması nedeniyle, tahmin doğruluğu açısından finansal verilerin sonuçları tatmin edici olmaktan uzaktır. Hisse senedi piyasalarındaki doğrusal-olmayan durumlar ve karmaşık ilişkiler göz önüne alındığında, zaman-serisi yaklaşımları bu özellikleri yakalayamayabilir.

Bu nedenle, sinir ağları gibi doğrusal-olmayan ve daha esnek modeller, doğrusal modellere göre modelleme ve öngöründe bulunma konularında, daha iyi sonuçlar üretebilmektedir (Georgescu & Dinucă, 2011:412; Ghiassi vd., 2006:302; Güreşen vd., 2011:10389; Qi, 1999:419; Quah, 2007:3; Şahin vd., 2012:4609 & Soni, 2011:71). Buna ilave olarak, Nazarian vd. (2013) klasik yöntemlere göre, fiyatların gelecekteki eğilimini daha yüksek doğrulukla tahmin edebiliyor olmasından dolayı, klasik ağlar ve sinir ağları (hibrit modeller) kombinasyonunun, etkin piyasa hipotezinin doğru olup olmadığına ilişkin fikir birliği eksikliğini bir tepkisi olarak ortaya çıktığını öne sürmüşlerdir (Abounoori vd., 2013; Hajizadeh vd., 2012:431, Khan & Gour, 2013:11; Merh vd., 2010:23; Pai ve Lin, 2005:497 & Wei vd., 2011:13625).

GARCH modellerinin finans alanındaki en önemli uygulamalarından birisi tahmin etmedir. Volatilitenin çeşitli finansal karar-verme modelinde kilit bir girdi olduğu göz önüne alındığında, bir modelin volatilitéyi tahmin etme performansı son derece önemlidir. Bu araştırmanın arkasındaki mantık daha doğru volatilité tahminleri üretilmesidir. Bu amaçla, Türkiye Menkul Kıymetler Borsası Endeksi BIST-100 volatilitésinde daha yüksek tahmin doğruluğu elde edilmesi amacıyla, GARCH-tipi modelleri Yapay Sinir Ağları ile iki farklı şekilde birleştirilmiştir. Daha spesifik olarak, ilk olarak Box ve Jenkins (1976) metodolojisi kullanılarak bir ARMA modeli ile hisse senedi endeksinin getiri serisi modellenmiştir. İkinci adımda, iki asimetrik GARCH modeli olan EGARCH ve GJR-GARCH Modellerinin uygunluğu değerlendirilmiş ve karşılaştırılmıştır. Üçüncü adımda, bir ANN Modeli tahmin edilmiştir. Ardından ANN-GARCH modeli ve GARCH-ANN Modeli olmak üzere iki hibrit model oluşturulmuştur. Dört Modelin (asimetrik GARCH Modeli, ANN Modeli ve iki hibrit Model) her birinden elde edilen tahminler, gerçekleşen volatilitéye yakınlık açısından birbiriyle karşılaştırılmıştır.

Çalışmada; eğitim setindeki tahminler için 1194 gözlem kullanılarak, 3 Ocak 2000 ila 26 Aralık 2022 arasındaki haftalık zaman-serisi verileri kullanılmıştır.

1. LİTERATÜR ARAŞTIRMASI

Son yıllarda yapay sinir ağı modelleri, zaman serisi tahminlerinde diğer modellere göre üstünlüğünü kanıtlamıştır. Bu konuda yapılan en eski çalışmalardan birisinde Kryzanowski vd. (1993) pozitif getiriye sahip hisse senetleri ile negatif getiriye sahip hisse senetleri arasında ayırım yapmak için finansal verileri ve yedi makroekonomik değişkeni kullanarak bir sinir ağı performansını incelemiştir. Bulguları, sinir ağının, yüksek olarak kabul edilen bir doğrulukla pozitif/negatif getirilerin %72'sini sınıflandırdığını öne sürmektedir. Donaldson ve Kamstra (1997), volatilitenin hisse senedi getirileri üzerindeki etkisinin yakalanması için semi-nonparametrik non-linear GARCH modeliyle bir sinir ağı kombinasyonunu tanıtarak, Toronto, New York, Tokyo ve Londra'da hisse senedi getirisi volatilitelerini tahmin etme yeteneğini değerlendirmiştir. Örnek-dışı-tahmin sonuçları, ANN Modellerinin (yapay sinir ağı modelleri) GARCH, EGARCH ve GJR-GARCH modellerini geride bıraktığını göstermektedir.

Qi ve Maddala (1999), hisse senedi fiyatı tahmini üzerinde bir sinir ağı modeli kullanan doğrusal bir regresyon modelindeki öngörücü gelişimi göstermiştir. Sonuçları büyük ölçüde örneklem dışı kalmaktadır. Schittenkopf vd. (2000), bir sinir ağı çerçevesi kullanarak koşullu şartlı tahminde bulunmak için yarı parametrik olmayan bir model oluşturmuşlardır. Tekrarlayan karışım yoğunluğu ağları, GARCH-tipi modellerin temel fikirlerine dayanıyordu, ancak aynı zamanda, daha yüksek değerde zamana bağlı anlara izin veren herhangi bir sürekli koşullu yoğunluğu modellemeyi de başarmıştır. Araştırmacılar, modellerini FTSE100 getirilerinde kullanmışlar ve bulguları, örneklem dışı tahminin GARCH modellerinden biraz daha iyi bir performans gösterdiğini desteklemektedir. Meissner ve Kawano (2001), GARCH ve yapay sinir ağlarının kombine bir modelinin finansal piyasalardaki spot varlıkların vade ve faiz oranlarının tahmininde Black-Scholes modeline kıyasla çok daha sağlıklı ve güvenilir sonuçlar verdiğini tespit etmişlerdir.

Roh (2007), bir hisse senedi fiyat endeksi volatilitelerinin tahmini için zaman-serisi ve sinir ağı modelleriyle hibrit modelleri iki şekilde önermiştir: yön ve sapma. Modelini Güney Kore borsasında kullanmıştır ve sonuçları, zaman-serisi modelleriyle birleştirilmiş sinir ağı tahmininin faydasını ortaya çıkarmıştır. Bildirici ve Ersin (2009), İstanbul borsasındaki günlük getirilerin volatilitelerini incelemek için GARCH-tipi modelleri kullanmış ve bu modelleri sinir ağı modelleriyle geliştirmiştir. Hibrit modelleri gelişmiş tahminler göstermektedir. Dhamija ve Bhalla (2010) araştırmalarında 5 döviz kuru serilerinin öngörülerinin kesinliğini yapay sinir ağları ve ARCH, GARCH, gibi koşullu değişen varyans modelleri ile karşılaştırmıştır. Analiz sonucunda IGARCH ve TGARCH modellerinin diğerlerine kıyasla çok daha doğru sonuçlar verdiğini tespit etmişlerdir. Vejendla ve Enke (2013a) ileri beslemeli yapay sinir ağları, yinelemeli sinir ağları ve GARCH yapılarının öngörü güçlerini mukayese etmişlerdir. Akabinde Vejendla ve Enke (2013b) aynı metodu opsiyon pazarlarındaki volatilitenin öngörüsünde uygulamıştır.

Kristjanpoller vd. (2014), Brezilya, Şili ve Meksika olmak üzere üç Latin Amerika ülkesindeki hisse senedi piyasasının volatilitelerini tahmin etmek için hibrit bir sinir ağı-GARCH modelini test etmiştir. Bulguları, ANN Modellerinin (yapay sinir ağı modeli) GARCH-tipi modellerin tahmin performansını artırdığını ve sonuçların çeşitli ANN spesifikasyonları ve volatiliteler için sağlam olduğunu desteklemektedir. Monfared ve Enke (2014), ABD'deki finansal piyasalar için

1997-2011 periyodunda volatilité tahmininde GARCH ve ANN modellerini kullandıkları çalıřmalarında GJR (1,1) modelinin sađlıklı sonuçlar verdiđini gözlemlenmişlerdir.

Lu vd. (2016), ANN ile asimetric GARCH modellerini birleřtiren iki hibrit model türü, yani EGARCH ve GJRGARCH arasındaki volatilité tahmin dođruluđunu karřılařtırmışlardır. Elde ettikleri sonuçlar, EGARCH-ANN hibrit modelinin, Çin enerji piyasasının volatilitésini tahmin etme açısından diđer modellerden daha iyi performans gösterdiđini ortaya koymaktadır. Çam vd. (2017), ARCH, GARCH ve yapay sinir ađları modelleri yardımıyla bir dizi finansal deđişken kullanılarak petrol fiyatlarını tahmine yönelik çalıřmalarında petrol fiyatları üzerinde en çok etkiye sahip parametreler olarak Dow Jones ve FTSE endeksleri saptanmıştır. Lahmiri (2017), iki GARCH modelinin (GARCH ve EGARCH), iki hibrit modelin (GARCH-ANN ve EGARCH-ANN) ve bir dizi teknik göstergeye sahip bir yapay sinir ađı'nın öngörü yeteneđini karřılařtırmıştır. Sonuçlar, MAE, MSE ve Theil's eşitsizlik katsayısı açısından, bir sinir ađı basit yaklaşıminin, diđer modellere kıyasla iki döviz kurunun (ABD/Kanada ve ABD/Euro) volatilitésini daha dođru bir şekilde tahmin ettiđini göstermiştir. Bhattacharya ve Ahmed (2018), Hindistan'daki ham petrolün volatilitésini analiz etmişler ve GARCH modellerine göre hibrit modellerin lehine geliřen sonuçlar elde etmişlerdir. Daha spesifik olarak, çeřitli GARCH-tipi modelleri hibrit GARCH-ANN Modelleriyle karřılařtırarak petrolün volatilitésini tahmin etmeye çalıřmışlardır. MSE indeksine dayanarak, EGARCH-ANN'nin modeller arasında en iyi tahmin yeteneđini sađladığını ortaya çıkarmışlardır. Ancak hibrit modele girdi olarak bir döviz kurunun (Hindistan Rupisi/Suudi Arabistan Riyali) eklenmesi daha fazla bir iyileşme sađlamamıştır.

Ramos-Perez vd. (2019), S&P500 için 2000'den 2017'ye kadar olan verileri kullanarak ve volatilitéyi tahmin etmek için hibrit bir model oluşturmuşlardır. Hibrit modelleri, makine öğrenimi tekniklerine dayanmakta olup, bunu iki GARCH tipi ANN Modeli (yapay sinir ađları modeli) ve Heston's (1993) modeli ile karřılařtırmışlardır. RMSE indeksine dayalı bulguları, örneklemin bölündüğü beş alt dönemin tamamında modellerinin üstünlüđünü desteklemiştir. Liu ve So (2020), 2 Mart 2018 ile 28 Şubat 2020 periyodu için Tensorflow için hisse senetlerinin volatilité tahmininde GARCH ve yapay sinir ađlarından yararlandıkları arařtırmalarında GARCH (1,1) modelinin sađlıklı ve güvenilir sonuçlar verdiđini ortaya koymuşlardır. Özbey ve Paksoy (2020), yalın ve hibrit modeller ile Borsa İstanbul 100 fiyat endeks getirisinin volatilitésini tahmine yönelik arařtırmalarında, hibrit modellerinin tahmin başarısı, bileşenlerinin tahmin gücü ile kıyaslanmıştır. EGARCH ve yapay sinir ađları bileşkesi olan hibrit modelin en başarılı model olduđu ortaya çıkarken, finansal enstrümanların risk analizinde hibrit modellerin sađlayabileceđi üstünlükler belirgin bir şekilde ispatlanmıştır.

Metin vd. (2020), çok deđişkenli GARCH türü yapılardan sađlanan volatilité deđerlerinin yapay sinir ađlarında çıktı tabakası biçiminde bulunmasıyla elde edilen hibrit model sayesinde Eylül-1992 ve Temmuz-2019 periyodu için petrol fiyatlarındaki dalgalanma incelenmiş olup, en dođru sonuçlara dinamik kořullu korelasyon yapısı (DCC-MGARCH) ve çok tabakalı algılayıcı yapı (MLP) tarafından meydana getirilen model yapısıyla eriřildiđi tespit edilmiştir. De Clerk ve Savelev (2022), yapay sinir ađları ve GARCH modelleri yardımıyla finansal zaman serilerinin tahminini ele alan çalıřmalarında yapay sinir ađları modelinin, en büyük olabilirlik kestirimine kıyasla çok daha dođru sonuçlar verdiđini ortaya koymuşlardır.

Görüldüğü üzere literatürde, özellikle de yurt dışında finansal zaman serilerinin tahmininde GARCH ve yapay sinir ađları

ve bunların hibrit modellerinin kullanıldığı birçok çalışma gözlenmiştir. Türkiye açısından bu konuda yapılan çalışmaların son derece kısıtlı olmasından dolayı, bu çalışmanın söz konusu alanda bir boşluğu doldurabileceği düşünülmektedir.

2. METODOLOJİ

2.1. ARMA/GARCH Tipi Modeller

ARMA modellerinin, finansal değişkenleri tahmin etme araçları olarak geliştirilmesi ve kurulması, Box ve Jenkins (1976) metodolojisi olarak bilinmektedir. Zaman-serisi analizindeki bu yaklaşım, örneğin geldiği stokastik süreci yeterince tanımlayan bir ARMA (p, q) modelini bulma yöntemidir. ARMA modeli denklem 1, denklem 2 ve denklem 3 ile ifade edilebilir:

$$\Phi(B)r_t - \mu = \theta(L)\varepsilon_t, \dots, \varepsilon_t \mid \Omega_{t-1} \sim N(0, \sigma_t^2) \quad (1)$$

$$\Phi(B) = 1 - \varphi_1 B - \varphi_2 B^2 - \dots - \varphi_p B^p \quad (2)$$

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (3)$$

Burada r_t borsa endeksinin getirisidir, N sıfır ortalama ve koşullu varyans σ_t^2 ile koşullu normal yoğunluğu temsil etmektedir. Ayrıca, Ω_{t-1} , t-1 zamanına kadar mevcut bilgidir, B , t üzerinden geri kaydırma operatörüdür ve α seri ortalamasıdır.

$\Phi(B)$ ve $\theta(B)$ polinomları, sırasıyla otoregresif (AR) ve hareketli ortalama (MA) terimlerini ifade etmektedir ve birim daire içinde ters köklere sahip oldukları varsayılmaktadır.

Finansal piyasalarda, bir risk ölçüsü olarak volatilité, Black-Scholes Modeli vb. gibi çeşitli uygulamalarda, portföy ve risk yönetimi, türev fiyatlama, opsiyon fiyatlama için çok önemli bir bileşen haline gelmiştir.

Tarihsel ve zımnî (*ima edilen*) volatilitéye alternatif olarak, stokastik volatilité sürecine ve zaman-serisi modellemesine dayalı olarak çeşitli modeller geliştirilmiştir. Engle'nin (1982) ARCH modelinin ve Bollerslev'in (1986) GARCH modelinin geliştirilmesinden bu yana çeşitli genişletmeler önerilmiştir. En yaygın kullanılan modeller Nelson'ın (1991) asimetrik EGARCH modeli ve Glosten ve arkadaşlarının asimetrik GJR-GARCH modelidir (1993).

2.1.1. EGARCH

Üstel Genelleştirilmiş Otoregresif Koşullu Değişken Varyans (EGARCH) Modeli, fiyat dalgalanmasının koşullu varyans üzerindeki kaldıraç etkilerini hesaba katmak için Nelson (1991) tarafından önerilmiştir. Bu durum, negatif bir şokun (kötü haber), volatilité üzerinde aynı büyüklükteki pozitif bir şoktan (iyi haber) daha büyük bir etkiye sahip olabileceği anlamına gelmektedir.

EGARCH(1,1) modelinde koşullu varyans denklem 4'deki gibi logaritmik bir formda ifade edilmektedir:

$$\ln(\sigma_t^2) = \omega + \alpha_1 \frac{|\varepsilon_{t-1}|}{\sigma_{t-1}} + \gamma_1 \frac{\varepsilon_{t-1}}{\sigma_{t-1}} + \beta_1 \ln(\sigma_{t-1}^2) \quad (4)$$

Burada ω , α_1 , β_1 ve γ_1 değerlendirme için parametrelerdir. ε_{t-1} pozitif olduğunda veya iyi haberler olduğunda, ε_{t-1} 'nin genel etkisi $(\alpha_1 + \gamma_1) \varepsilon_{t-1}$ olacaktır. Tersine, eğer ε_{t-1} negatifse veya kötü haberler varsa, o zaman ε_{t-1} 'nin genel etkisi

$(\alpha_1 - \gamma_1)\varepsilon_{t-1}$ olacaktır. Başka bir deyişle, ε_{t-1} teriminin, $\gamma_1 \neq 0$ parametresi olduğunda EGARCH modelindeki asimetriyi hesaba katan terim olduğu düşünülmektedir. Bu nedenle, katsayı kaldıraç etkilerini belirleyen katsayıdır. İlave olarak, $\gamma_1 < 0$ olduğunda, pozitif bir şok, aynı büyüklükteki (asimetri) negatif bir şoka kıyasla daha az volatiliteye neden olmaktadır. Son olarak, EGARCH modelinde, olumsuz bir koşullu varyanstan kaçınmak için değerlendirme parametreleri üzerinde herhangi bir kısıtlama bulunmamaktadır. Bu modelde koşullu varyans σ_t^2 , ε_{t-1} 'in hem boyutuna hem de işaretine bağlı olarak değişmektedir.

2.1.2. GJR-GARCH

Zaman-serisinin volatilité asimetrisini ele alan bir diğer asimetrik model, Glosten vd. (1993) tarafından önerilen GJR-GARCH (1,1) modelidir. Formasyonu denklem 5 ile ifade edilmektedir:

$$\sigma_t^2 = \omega + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 + \gamma_1 I_{t-1} \varepsilon_{t-1}^2 \quad (5)$$

Aşağıdaki koşullar karşılandığı durumda, Model iyi tanımlanmıştır:

$$\alpha_1 + \beta_1 + \frac{1}{2}\gamma_1 < 1 \quad (6)$$

$$\omega \geq 0, \alpha_1 \geq 0, \beta_1 \geq 0 \text{ and } \alpha_1 + \gamma_1 \geq 0 \quad (7)$$

Denklem 5, 6 ve 7'de; ω , α_1 , β_1 ve γ_1 değerlendirme parametreleridir. I_{t-1} , eğer, $\varepsilon_{t-1} < 0$ ise 1, aksi takdirde 0 değerini alan bir kukla değişkendir.

Yukarıdaki model denklem 5, kötü haberin ($\varepsilon_t < 0$) ve iyi haberin ($\varepsilon_t > 0$) koşullu varyans üzerinde farklı etkileri olabileceğini düşündürmektedir. Eğer, γ_1 katsayısı pozitifse, o zaman asimetri vardır ve dolayısıyla kaldıraç etkileri bulunmaktadır. Kaldıraç etkisi, pozitif şoklardaki itmeden (α_1) daha büyük olan negatif şoklardaki toplam itme ($\alpha_1 + \gamma_1$) ile tanımlanmaktadır.

GARCH modellerinin parametreleri, maksimum olabilirlik yöntemi kullanılarak tahmin edilmiştir. Bağımsız ve aynı şekilde dağıtılmış random değişken z_t ($z_t = \varepsilon_t / \alpha_t$) için, Student-t dağılımı durumunda denklem 8'de verilen log olabilirlik fonksiyonunun maksimize edilmesi gerekmektedir:

$$L(\theta) = T \left[\ln \Gamma \left(\frac{v+1}{2} \right) - \ln \Gamma \left(\frac{v}{2} \right) - \frac{1}{2} \ln(\pi(v-2)) \right] - \frac{1}{2} \sum_{t=1}^T \left[\ln(\sigma_t^2) + (1+v) \ln \left(1 + \frac{z_t^2}{v-2} \right) \right] \quad (8)$$

$$\Gamma(v) = \int_0^{\infty} e^{-x} x^{(v-1)} dx \quad (9)$$

Denklem 9'da gama işlevi yer almakta olup, v serbestlik derecesini göstermektedir.

Standart Genelleştirilmiş Hata Dağılımı (GED) dikkate alındığında, log-olabilirlik işlevi denklem 10'daki formu almaktadır:

$$L(\theta) = \sum_{t=1}^T \left[\ln\left(\frac{v}{\delta}\right) - \frac{1}{2} \left| \frac{z_t}{\delta} \right|^v - (1 + v^{-1}) \ln(2) \right] - \ln \Gamma\left(\frac{1}{v}\right) - \frac{1}{2} \ln(\sigma_t^2) \quad (10)$$

$$\delta = \left[\frac{1}{2^{2/v}} \frac{\Gamma\left(\frac{1}{v}\right)}{\Gamma\left(\frac{3}{v}\right)} \right]^{1/2} \quad (\text{Dritsaki, 2017}).$$

Bu iki asimetrik GARCH-tipi model arasında seçim yapmak için, maksimum log-olabilirlik değeri, Akaike bilgi kriteri (AIC), Schwarz bilgi kriteri (SIC) ve Hannan-Quinn bilgi kriterleri kullanılmıştır.

2.2. Yapay Sinir Ağı Modeli

Daha önce de belirtildiği gibi, borsalarda veriler arasında doğrusal bir korelasyon yapısı varsayan GARCH modelleri tarafından yakalanamayan doğrusal olmayan durumlar da bulunmaktadır (Fahimifard vd., 2009). Bu nedenle, bu tür karmaşık problemlerle başa çıkmak için doğrusal modeller kullanmak yeterli sonuçlar vermeyebilir. ANN (yapay sinir ağları), insan beyninin verileri işleme ve kalıpları çıkarma yeteneğini taklit etmeye çalışan bir hesaplamalı modeldir (Luo & Shah, 2007). İnsan beyninin yapısına bağlı olarak, bir dizi nöron birbirine bağlıdır ve katmanlar halinde düzenlenmektedir. Bu katmanlar girdi katmanları, gizli katmanlar ve çıktı katmanları olarak sınıflandırılmaktadır.

Bu tür modellerin en büyük avantajlarından birisi, en azından teorik olarak, herhangi bir sürekli fonksiyonu andırabilmeleridir, yani araştırmacıların bu durumda, temel model hakkında herhangi bir hipotez varsaymasına gerek bulunmamaktadır (Pakdaman vd., 2017).

Yapay sinir ağları, ileri-beslemeli ve geri-beslemeli ağlar olmak üzere iki kategoriye ayrılmaktadır. Her iki ağ da birbirine bağlı nöronlardan oluşur ve bir nöronun diğer nöronları etkilemesine izin verir. İleri-beslemeli ağlar, sinyallerin yalnızca girişten çıkışa gitmesine izin verirken, geri-beslemeli ağlar, ağda döngüler oluşturarak iki yönlü bir iletişime izin verebilmektedir. Ayrıca, geri yayılım algoritmasına sahip ileri-beslemeli Sinir Ağları, Modelin parametrelerini stokastik bir gradyan azalışı yoluyla yeniden değerlendirmesine izin vererek, tahmin süreci sırasında kayıp fonksiyonuyla uyumlu olmasını sağlarlar (Lu vd., 2016). Stokastik gradyan azalışı, kuadratik hataları en aza indiren bir optimizasyon algoritmasıdır. Başka bir deyişle, bu araştırma, finansal uygulamalarda en yaygın olarak kullanılan (BPNN olarak adlandırılan) Geri Yayılımlı Sinir Ağlarını kullanmaktadır (Hajizadeh vd., 2012; Ko, 2009; Lu vd., 2016; Tseng vd., 2008 & Wang, 2009).

Eğitim setini aşırı-uydurma ve verilerin gerçek istatistiksel sürecini yakalayamama olasılığıyla başa çıkmak için araştırmada, sadece bir gizli katman ayarlanmıştır. Genel olarak, gizli katmanların sayısı artırıldığı durumlarda, aşırı-uydurma tehlikesi de artmaktadır ve bu durum da örnek dışı tahmin performansının zayıflamasına neden olmaktadır.

Çalışmada bir girdi katmanı, bir gizli katman ve bir çıktı katmanı seçilmiştir. Her üç katman da vektörler olarak temsil edilebilir. Girdi katmanı $= (x_1, x_2, \dots, x_d)$, gizli katman $m = (h_1, h_2, h_3)$ ve çıktı katmanı $c = (y_1)'$. Geri Yayılımlı Sinir Ağı, girdilerin ağırlıklı doğrusal toplamından denklem 11'deki gibi türetilmektedir:

$$a_j = \sum_{i=1}^d w_{ji}x_i \quad (11)$$

Gizli j birimini etkinleştirmek için, bir lojistik aktivasyon fonksiyonu $g(a)$ kullanarak,

Denklem 11 doğrusal toplama dönüştürülmektedir:

$$h_j = g\left(\sum_{i=1}^d w_{ji}x_i\right) \quad (12)$$

$$g(a) = \frac{\exp(a)}{(1+\exp(a))} \quad (13)$$

Çıkış katmanının nöronu denklem 14'de tarif edilmektedir:

$$y_1 = g\left(\sum_{j=1}^3 w_{1j} g\left(\sum_{i=1}^d w_{ji}x_i\right)\right) \quad (14)$$

burada giriş sayılarına karşılık gelir ($i = 1, 2, \dots, d$),

j üç olan gizli nöron sayısına karşılık gelmektedir ($j = 1, 2, 3$).

w_{ji} giriş katmanından gizli katmana olan ağırlıklardır.

w_{1j} gizli katmandan çıkış katmanına doğru olan ağırlıklardır.

Ayrıca, değer sonuçlarını çıkartabilmek için, verilerin sinir ağına yüklenmesinden önce normalleştirilmesi önemlidir.

Bu amaçla, verilerin tüm değerlerini $[0,1]$ aralığına getiren ve denklem 15'de verilen min-maks özellik ölçeklendirmesi uygulanmıştır:

$$x' = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (15)$$

Burada x orijinal veridir, x_{min} ve x_{max} sırasıyla minimum ve maksimum verilerdir ve x' normalleştirilmiş veridir. Sinir ağının çıktısı daha sonra Denklem 14 kullanılarak x in çözüldüğü şekilde de-normalize edilir. Ayrıca gerçek finansal verilerle yeterli bir yapay sinir ağı oluşturulması için veri seti, toplam gözlemlerin %90'ını oluşturan eğitim seti ve kalan %10'luk kısım ile test seti olmak üzere iki alt kümeye ayrılmıştır (Lewis, 2017: 53).

2.3. Hibrit Modeli

Bu çalışmada, borsa endeksinin volatilitésinin tahmin edilmesi için, bir ölçüde, Lu vd. (2016), çalışmasını takip eden iki hibrit model uygulanmıştır. Başlangıçta, Box-Jenkins Metodolojisi kullanılarak bir ARMA Modeli oluşturulmuştur ve diğer bir model olarak ta, bazı kriterlere (Maksimum Olabilirlik, Akaike, Schwarz ve Hannan-Quinn) dayalı olarak tercih edilen, GARCH-tipi bir model (EGARCH veya GJR-GARCH modeli) kullanılarak, hibrit modeller oluşturulmuştur. Ardından, seçilen açıklayıcı girdi değişkenlerinden bir sinir ağı öngörülmüştür.

2.3.1. Tip I Hibrit Model: ANN-ARMA-GARCH

Tip I Model, ARMA-GARCH-tipi Modelin koşullu volatilité sonucunun ANN'ye girilmesiyle oluşturulmuştur. Başka bir deyişle, tercih edilen ARMA-GARCH modelinin çıktısı, yani tahmin edilen koşullu varyans, ANN Modelinin borsa endeksinin volatilitésine ilişkin tahmin performansını artırmak için girdi deđişkeni olarak kabul edilmiştir.

2.3.2. Tip II Hibrit Modeli: ARMA-GARCH-ANN

Tip II Model, ANN modelinin çıktı katmanını olan y_1 'i ARMA-GARCH tipi modelin varyans denklemine bir deđişken olarak dahil ederek oluşturulmuştur.

EGARCH-ANN

$$\ln(\sigma_t^2) = \omega + \alpha_1 \frac{|\varepsilon_{t-1}|}{\sigma_{t-1}} + \gamma_1 \frac{\varepsilon_{t-1}}{\sigma_{t-1}} + \beta_1 \ln(\sigma_{t-1}^2) + \xi_1 y_1 \quad (16)$$

GJR-GARCH-ANN

$$\sigma_t^2 = \omega + \alpha_1 \varepsilon_{t-1}^2 + \beta_1 \sigma_{t-1}^2 + \gamma_1 I_{t-1} \varepsilon_{t-1}^2 + \xi_1 y_1 \quad (17)$$

2.4. Kapsamlı Tahmin

Tahmin serilerinin görelî özelliklerini incelemek için Cook'un (2012) çalışmasını izleyerek iki Kapsamlı Tahmin Testi uygulanmıştır. Birincisi Fair ve Shiller (1989) testidir. Bu test, denklem 18'deki regresyondan türetilir:

$$RV_t = c + \lambda_1 f_{1,t} + \lambda_2 f_{2,t} + u_t \quad (18)$$

Burada RV_t gerçekleşen volatilitedir,

c bir sabittir,

$f_{1,t}$ Model 1'den yapılan volatilité tahminidir ve

$f_{2,t}$ Model 2'den yapılan volatilité tahminidir.

$\lambda_1 = 0$ ve $\lambda_2 \neq 0$ olduğunda, Model 2 tahmini, Model 1'i kapsamaktadır (daha iyi performans gösterir).

Tersine, eđer $\lambda_1 \neq 0$ ve $\lambda_2 = 0$ ise, Model 1 tahmini Model 2'yi kapsamaktadır.

Hem $\lambda_1 \neq 0$ ve hem de $\lambda_2 \neq 0$ olması durumunda sıfır hipotezini reddedilememektedir ve her iki tahmin de bağımsız bilgiler içermektedir.

İkinci test, bir tahminin diđerinin hatasını açıklama yeteneđine dayanmaktadır. Tahmin hatası, bir tahminin yakalayamadıđı bir bilgi olarak kabul edilebilir.

Tahmin hatasını

$$e_{i,t} = RV_t - f_{i,t} \quad (19)$$

olarak gösteren Chong ve Hendry (1986) testinin regresyonları denklem 20 ve 21'deki gibi verilmektedir:

$$e_{1,t} = \lambda_2 f_{2,t} + v_{1,t} \quad (20)$$

$$e_{2,t} = \lambda_1 f_{1,t} + v_{2,t} \quad (21)$$

Eğer, Model 1'in ($e_{1,t}$) tahmin hatası, Model 2'nin tahmini ($f_{2,t}$) ile ilgili değilse, yani $\lambda_2 = 0$ ise, o zaman tahmin 1 kendi başına kullanılabilir.

Aksine, tahmin hatası diğer tahminden etkilenirse, hem ($f_{1,t}$) hem de ($f_{2,t}$)'yi içeren bileşik bir tahmin oluşturulmalıdır.

3. VERİ ÖZELLİKLERİ

Çalışmada; eğitim setindeki tahminler için 1194 gözlem kullanılarak, 3 Ocak 2000 ile 26 Aralık 2022 arasındaki haftalık zaman serisi verileri kullanılmıştır. Veri seti, Türkiye menkul kıymetler borsasını temsil eden BIST-100 borsa endeksinin haftalık fiyatlarından oluşmaktadır. Bu çalışmada, daha az gürültülü olduğu için haftalık veriler kullanılmaktadır. Hisse senedi verileri Matriksdata firmasından temin edilmiştir. Önceki çalışmalarla uyumlu olarak, sürekli bileşik haftalık getiriler r_t ilk log-farkı olarak denklem 22'deki gibi hesaplanmıştır,

$$r_t = 100 \times \ln(P_t / P_{t-1}) \quad (22)$$

Burada P_t haftalık kapanış fiyatıdır.

4. BULGULAR

Tablo 1: BIST-100 Endeksi İçin Haftalık Getirilerin Ön İstatistiksel Özellikleri


Mean	707.6806	Q(2)	2.9281
Stn. Dev.	650.8590	Q(4)	-15.38202***
Median	611.1200	Q(6)	-21.41084***
Min	73.06000	Q ² (2)	92.778***
Max	5504.090	Q ² (4)	234.998***
Skewness	3.168242	Q ² (6)	119.369***
Kurtosis	18.29751	ADF	11.854***
Jarque-Bera	13639.71***	Obs.	1194

St. Sapma / Medyan / Minimum / Maksimum / Çarpıklık / Basıklık / Jarque Bera *** ve **Sırasıyla %1 ve %5'te istatistiksel anlamlılığı göstermektedir. ADF, Artırılmış Dickey-Fuller testlerini ifade etmektedir (Dickey ve Fuller, 1979). ADF denklemleri için gecikme uzunlukları, Schwarz Bilgi Kriteri (SIC) kullanılarak seçilmiştir. MacKinnon (1996) birim kök hipotezinin reddi için kritik değerler uygulamıştır. Serilerin seri korelasyonu ve gecikmelerde kareli seriler Ljung-Box istatistikleridir (Ljung ve Box)

Tablo 1'de eğitim setinin geri dönüş serisinin ön istatistiksel özellikleri sunulmaktadır. Buna göre, seri pozitif bir ortalama sunmaktadır ve standart sapması ortalama değere oldukça yakındır. Seri, GARCH-tipi modellerin yeterli olduğunu ima eden yüksek frekanslı finansal verilerde oldukça yaygın bir durum olan negatif çarpıklık ve büyük miktarda basıklık göstermektedir. İlave olarak, normalliğin sıfır hipotezi, Jarque ve Bera (1980) test istatistiği tarafından %1 anlamlılık düzeyinde reddedilmiştir. Ljung ve Box'ın (1978) (değişken varyans) otokorelasyonunun tespiti için kullanılan (kare) Q-istatistiği önemlidir ve piyasanın geçmiş davranışının daha fazla ilgili olabileceğini ifade etmektedir. Son olarak, kuvvetlendirilmiş Dickey ve Fuller (1979; 1981) birim kök testi, getiri serisinin %1 anlamlılık düzeyinde durağan olduğunu göstermektedir.


Şekil 1 ve Şekil 2, sırasıyla deneysel veri seti için BIST-100 endeksini ve 1. derece farklarını göstermektedir.

BIST-100 Endeks Kapanış



Şekil 1: BIST-100 Endeksi Kapanış Değerleri

BISTFARK



Şekil 2: BIST-100 Endeksi Fark Değerleri

Şekil 1’de, BIST-100 endeksi kapanış değerleri görülmekte olup, seri durağan değildir. Şekil 2’de ise BIST-100 endeksi fark değerleri yer almakta olup, görüldüğü üzere fark alma işleminden dolayı seri durağan bir görünüm arz etmektedir.

Tahmin doğruluğunu değerlendirmek için, bu araştırma Pagan ve Schwert (1990) (Day & Lewis, 1992; Franses & Van

Dijk, 1996 & Wei, 2002) çalışmalarıyla uyumludur ve dört modelin volatilité tahminlerini gerçekleŝen volatilité deęerleriyle karŝılaŝtırmaktadır. t gününde gerçekleŝen volatilité² (RV) denklem 21'deki gibi hesaplanmaktadır:

$$RV_t = (r_t - \bar{r})^2 \quad (23)$$

Denklem 21'de \bar{r} ortalama logaritmik getiridir. Ayrıca, modellerin volatilité tahminindeki performansını deęerlendirmek için Ortalama Mutlak Hata (MAE), Simetrik Ortalama Mutlak Yüzde Hatası (SMAPE) ve Kök Kare Hatası (RMSE) olmak üzere üç metrik kullanılmaktadır. Metrikler aŝağıdaki ŝekilde tanımlanmaktadır:

$$MAE = \frac{1}{n} \sum_{i=1}^n |\sigma_i - RV_i| \quad (24)$$

$$SMAPE = \frac{1}{n} \sum_{i=1}^n \frac{|\sigma_i - RV_i|}{|\sigma_i| + |RV_i|} \quad (25)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (\sigma_i - RV_i)^2} \quad (26)$$

Bu çalışma, GARCH-tipi modellerin sadece $p = 1$ ve $q = 1$ mertebelerine, yani EGARCH(1,1) ve GJRARCH(1,1)'e odaklanmaktadır. Brooks'un (2008) belirttięi gibi, GARCH(1,1) finansal verilerdeki volatilité kümelenmesini yakalamak için yeterli olacaktır ve nadiren herhangi bir üst düzey model tahmin edilmektedir. Getirilerin basıklığı, getiri serisini tanımlamak için ŝiŝman-kuyruk daęılımının gereklilięini gösteren 3 deęerini aŝtıęı için, student-t ve GED daęılım hataları dikkate alınmıŝtır.

Box-Jenkins metodolojisine göre getiri serilerinin ortalama özelliklerini modellemek için ARMA(2,2) modeli tercih edilmiŝtir.

Tablo 2: Eęitim Seti Kullanılarak ARMA Modelinin Parametre Tahmini

Parametre	c	AR(1)	AR(2)	MA(1)	MA(2)
Katsayı	1.887	3.348***	3.337***	2.111***	*1.117**
Artık teŝhis					
Q(8)	3.338	Q ² (8)	225.887***	ARCH(6)	51.774***
Q(12)	6.997	Q ² (12)	246.884***	ARCH(8)	56.337***
Q(16)	19.228	Q ² (16)	266.477***	ARCH(12)	59.996***
Q(18)	52.147	Q ² (18)	269.887***		
Q(22)	58.227	Q ² (22)	296.337***		
Q(24)	63.987	Q ² (24)	305.128***		

***% 1'de istatistiksel anlamlılıęını göstermektedir. Q(i) ve Q²(i), i'inci gecikmelerde seri ve karesi alınmıŝ serilerin seri korelasyonu için Ljung-Box istatistikleridir (Ljung ve Box, 1978). ARCH(i), Engle'nin (1982) ARCH testinin i'inci gecikmelerdeki F istatistięini temsil etmektedir.

Tablo 2, ARMA modelinin katsayılarını ve artık tanımlamalarını göstermektedir. Bulgular, BIST-100 indeksinin getirilerinin, $t-1$ e $t-2$ zamanlarındaki gecikmeli getirilerinden olumlu etkilendięini göstermektedir. Ayrıca, Q istatistikleri, bu spesifikasyonun seri korelasyonu yakalamak için yeterli olduęunu göstermektedir, ancak, kare Q istatistikleri ve ARCH testleri dikkate alındığında, koŝullu deęiŝen varyansın yokluęuna iliŝkin sıfır hipotezi büyük ölçüde reddedilmektedir. Bu

nedenle, temel artıkların koşullu değişen varyansına uyması için GARCH Modellerinin gerekliliği doğrulanmaktadır.

Tablo 3: Bilgi Kriterlerinin Değerleri

Model	Distribution	Log-Likelihood	Akaike	Schwarz	Hannan-Quinn
EGARCH	t-Student	-9121.179	15.289	15.117	15.118
	GED	-9287.211	15.203	15.049	15.008
GJR-GARCH	t-Student	-9181.227	15.224	15.299	15.239
	GED	-9119.996	15.117	15.116	15.115

Kalın yazılmış sayılar optimum değerleri göstermektedir

Tablo 3, iki rekabetçi asimetrik GARCH modelinin her birisini, yani EGARCH(1,1) ve GJR-GARCH(1,1) ve ayrıca incelenen her dağıtım için bilgi kriterlerinin değerlerini göstermektedir. Akaike, Schwarz ve Hannan-Quinn kriterlerinin en düşük değerlerini, Log-Olasılık ise en yüksek değerini aldığı için GED dağıtılmış hatalara sahip EGARCH(1,1) modelinin en uygun Model olduğu açıktır. Bu nedenle, hibrit modellerin inşası için seçilen modeldir. Model aşağıdaki gibi oluşmuştur.

$$\text{GARCH} = 235.46646066 + 0.954825043152 * \text{RESID}(-1)^2 + 0.445083119548 * \text{RESID}(-2)^2 - 0.390395349622 * \text{GARCH}(-1)$$

Tablo 4: Eğitim Seti Kullanılarak EGARCH Modelinin Parametre Tahmini

Parametre	ω	α	γ	β	
Katsayı	0.887***	0.144***	-0.774***	0.966***	
Artık Teşhis					
Q(8)	16.135	Q ² (8)	5.117	ARCH(6)	0.117
Q(12)	19.685	Q ² (12)	6.781	ARCH(8)	0.441
Q(16)	24.640	Q ² (16)	8.296	ARCH(12)	0.663
Q(18)	24.927	Q ² (18)	8.919		
Q(22)	25.635	Q ² (22)	9.337		
Q(24)	31.683	Q ² (24)	9.993		

*** ve *İstatistiksel anlamlılığı sırasıyla %1 ve %10 olarak göstermektedir.

Q(i) ve Q²(i), i'inci gecikmelerde seri ve karesi alınmış serilerin seri korelasyonu için Ljung-Box istatistikleridir (Ljung ve Box, 1978). ARCH(i), Engle'nin (1982) ARCH testinin i'inci gecikmelerdeki F istatistiğini temsil etmektedir.

GED hatalarıyla ARMA(1,1)-EGARCH(1,1)'den elde edilen tahmini sonuçlar Tablo 4'te sunulmaktadır. γ parametresi istatistiksel olarak anlamlı ve negatif olduğundan, BIST -100 endeksinde kaldıraç etkileri bulunmaktadır. Bu durum, BIST-100 endeksindeki hisse senedi fiyatındaki dalgalanmanın volatilitesi üzerinde asimetrik bir etkiye sahip olduğunu göstermektedir. Bu bulgu, borsa İstanbul'un yatırımcıların irrasyonel kararlar alma ihtimalinin yüksek olduğunu göstermektedir. Ayrıca, artık teşhise dayalı olarak model, kalan ARCH etkilerini yakalayarak iyi bir performans sergilemektedir.

Hibrit modellerin kurulmasına geçmeden önce, ARIMA(1,1)-EGARCH(1,1) modeli ve ANN'den elde edilen tahminlerden yararlanarak Chong ve Hendry'nin (1986) tahmin kapsayan testi gerçekleştirilmiştir ve sonuçları Tablo 5'te gösterilmiştir.

Tablo 5: Tüm Test Setini Kapsayan Tahmin (EGARCH/ANN)

Regression	Dep. var.	f_{EGARCH}	f_{ANN}
1	e_{EGARCH}		0.774***
2	e_{ANN}	0.229**	

*** ve *, sırasıyla %1 ve %10'luk istatistiksel anlamlılığı göstermektedir.

İlk regresyondan, EGARCH modelinden elde edilen artıkların ($e_{EGARCH} = RV - f_{EGARCH}$), ANN (yapay sinir ağları) nin tahminlerinden etkilendiği görülmektedir. Aynı durum, ikinci regresyonun öne sürdüğü gibi ters yönden de geçerlidir. Bu durum, her iki tahmin serisinin de bileşik bir tahmin serisinin oluşturulmasına dahil edilmesi gerektiği anlamına gelmektedir. Bu nedenle, EGARCH modeli ve ANN'in tahminlerine dayanan basit bir ortalama tahmin (bundan sonra SM) kullanılmaktadır. Başka bir deyişle, eşit ağırlıklara sahip ağırlıklı bir ortalama uygulanmaktadır, yani hem EGARCH tahminleri hem de ANN tahminleri için ağırlıklar 0,5 e eşittir. SM tahminleri, örnek-dışı tahminlerin geri kalanıyla da karşılaştırılmaktadır.

Sinir ağının ve iki hibrit modelin oluşturulması için aşağıdaki özellikler kullanılmıştır. Gizli katmanda üç nöron ve çıkış katmanında bir nöron kullanılmıştır. Hedef değişken gerçekleşen volatilitedir. Ayrıca, geri yayılım algoritması, öğrenme oranı ve eşik değeri 0,01 olarak ayarlanarak kullanılmıştır. Kayıp fonksiyonu olarak hataların karesi toplamı, verilerin normalleştirilmesi için min-maks özellik ölçekleme formülü ve tüm katmanlar için aynı aktivasyon fonksiyonu, yani lojistik fonksiyonu kullanılmıştır. Girdilerin seçimi ile ilgili olarak, bu makale; Maciel ve Ballini'nin (2010) otokorelasyon analizi uygulanarak sinir ağına girdi olarak değişkenlerinin gecikmeli değerlerini kullanan çalışmasıyla da uyumludur.

Aynı şekilde, yapay sinir ağının, Box-Jenkins metodolojisinin sonuçları izlenerek, BIST-100 indeksinin getirileri ve t-1 ve t-2 zamanlarındaki gecikmeli değerleri ile beslenmesine karar verilmiştir (ayrıca Tablo 2 ARMA Modelinin, AR(1) ve AR(2) olmak üzere iki otoregresif terimden oluştuğuna bakılabilir.)

Tablo 6: Örneklem İçi Volatilitate Tahmin Performansı

Metric	EGARCH	ANN	Hybrid I	Hybrid II
4-weeks ahead				
MAE	9.501	5.311	3.089	7.638
SMAPE	0.289	0.151	0.052	0.258
RMSE	9.981	5.391	3.309	8.994
25-weeks ahead				
MAE	10.22	4.572	2.41	7.202
SMAPE	0.195	0.064	0.024	0.131
RMSE	12.007	4.971	2.704	9.583
50-weeks ahead				
MAE	9.675	6.037	2.161	7.331
SMAPE	0.116	0.024	0.104	0.055
RMSE	13.189	10.938	2.513	11.928
100-weeks ahead				
MAE	9.451	6.715	2.383	7.888
SMAPE	0.144	0.08	0.048	0.109
RMSE	13.458	11.361	2.712	12.587

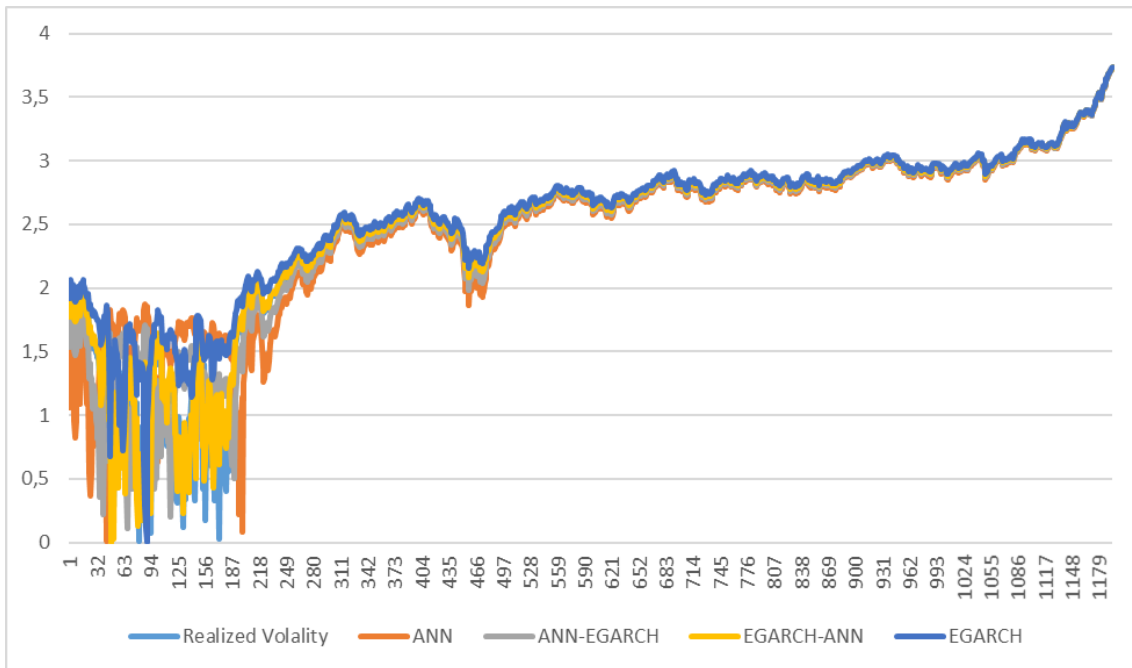
Kalın yazılmış sayılar optimum değerleri göstermektedir.

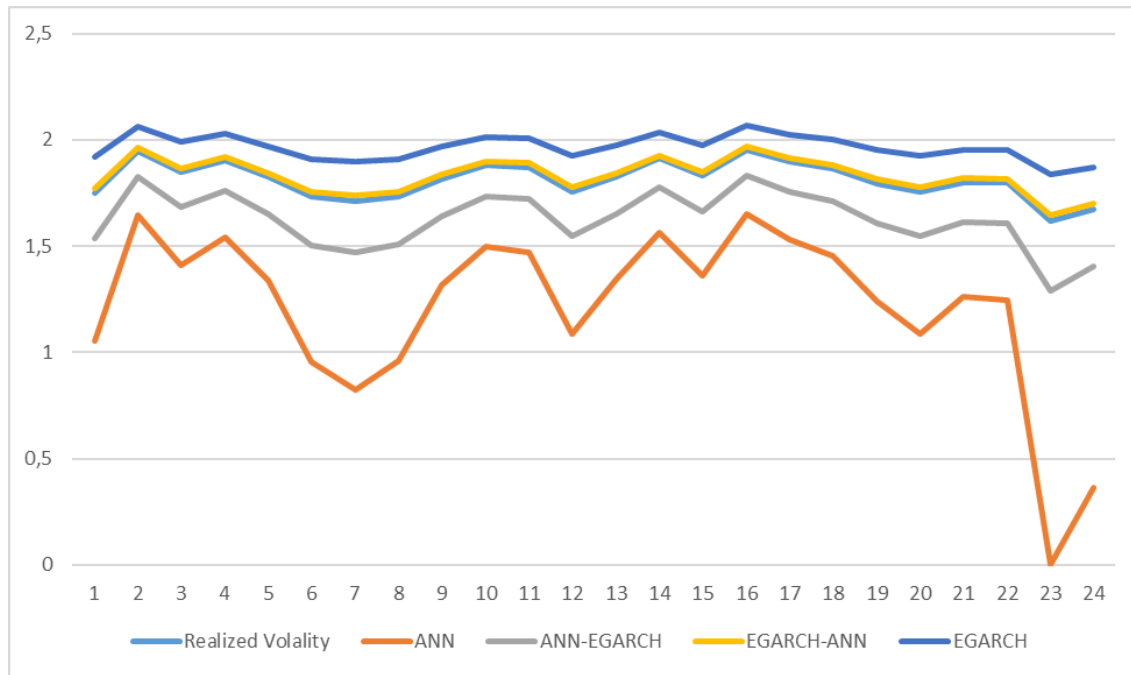
Tablo 7: Örneklem Dışı Volatilite Tahmin Performansı

Metric	EGARCH	ANN	Hybrid I	Hybrid II	SM
4-weeks ahead					
MAE	44.7774	11.2724	5.9474	86.7544	44.7774
SMAPE	0.64	0.444	0.251	0.641	0.64
RMSE	57.413	5.43	-1.357	93.876	57.413
25-weeks ahead					
MAE	25.0994	11.3154	5.6494	29.0044	25.0994
SMAPE	0.676	0.562	0.405	0.628	0.676
RMSE	27.877	10.594	-1.529	40.152	27.877
50-weeks ahead					
MAE	19.4394	10.5584	5.2284	20.4404	19.4394
SMAPE	0.674	0.577	0.426	0.637	0.674
RMSE	20.231	9.179	-1.935	28.295	20.231
100-weeks ahead					
MAE	12.9134	9.2864	5.1844	13.4024	12.9134
SMAPE	0.727	0.699	0.578	0.708	0.727
RMSE	13.138	5.889	-2.094	18.731	13.138

Kalın yazılmış sayılar optimum değerleri göstermektedir. SM, EGARCH ve yapay sinir ağ modelleri için basit ortalama tahmini göstermektedir.

Daha güvenilir sonuçlar elde etmek için, dört farklı zaman ufkunu, yani 4-hafta, 25-hafta, 50-hafta ve 100-haftayı test ederken, hem örnek içi hem de örnek dışı tahminlerde dört rekabetçi modelin öngörü yeteneği karşılaştırılmıştır. Şekil 3 ve Şekil 4'te normalleştirilmiş tahminlere dayalı olarak her bir model için metriklerin değerleri gösterilmektedir.

**Şekil 3:** Örneklem İçi Volatilite Tahminleri



Şekil 4: Örneklem Dışı Volatilite Tahminleri

Şekil 3 ve Şekil 4’te, sırasıyla, örnek içi ve örnek dışı tahminler için gerçekleşen volatilitelere karşı tahmin edilen volatilitenin grafiği sunulmaktadır. Örneklem-içi volatilitte tahminlerinin sonuçları Tablo 6’da rapor edilmiştir. Hibrit Tip I modelinin (ANN-ARMA (1,1)-GARCH (1,1)-GED) tüm zaman ufuklarında ve tüm de-normalize edilmiş ölçümler için tahmin yetenekleri açısından, diğer modellerden daha iyi performans gösterdiği açıkça görülmektedir. BIST-100 endeksinin volatilitesini tahmin etmek için en iyi ikinci model, basit sinir ağı modeli iken, iki GARCH-tabanlı modelin volatilitte tahmin kesinliği tatmin edici olmaktan uzaktır ve EGARCH Modeli en kötüsüdür. En doğru tahminlerin 25 haftalık bir ufukta elde edilmesi ve tahmin zaman ufku arttıkça metriklerin daha iyi olması (değer olarak küçülmesi) de ayrıca ilginçtir.

İlgimizi örneklem dışı volatilitte tahminlerine çevirdiğimizde, Tablo 7 aynı örüntüyü ortaya çıkarmaktadır ki bu, tüm durumlar için gerçekleşen volatilitedeki yakınlık açısından, Hibrit Tip I modelinin diğer modellere karşı üstünlüğü ortaya çıkmaktadır. ANN modeli yine ikinci sırada kalmaktadır, bu durumda Hibrit II modeli BIST-100 endeksinin oynaklığını en zayıf şekilde tahmin edebilmektedir. Ayrıca, MAE ve RMSE metriklerinin daha düşük değerlerinin de gösterdiği gibi, zaman ufku ne kadar uzunsa, modeller o kadar iyi performans göstermektedir.

Ancak, SMAPE metriği dikkate alındığında durum böyle değildir. SM tahminleri, ANN tahminlerinden biraz daha kötüdür, ancak EGARCH modelinden daha iyi performans göstermektedir. Ancak, bu bileşik tahmin Hibrit I modelinin tahmin gücüne ulaşamamaktadır. Beklendiği gibi, örneklem-dışı tahminlerdeki metriklerin değerleri, örneklem-içi tahminlerdeki karşılık gelen değerlerden daha yüksektir, bu durum yüklenen verilerin gerçek verilere genelde tahmin edilenlerden daha yakın olduğunu vurgulamaktadır.

Tablo 8: Örneklem Dışı 100 Haftalık Ufuk İçin Kapsayan Tahmin (Fair and Shiller)

Regression	Constant	$f_{Hybrid I}$	f_{EGARCH}	f_{ANN}	$f_{Hybrid II}$	f_{SM}
1	3.557***	1.558***	0.236***			
2	3.793***	1.549***		-0.362		
3	2.365***	1.119***			0.632***	
4	1.991***	0.885***				0.005

Dört regresyonun her birindeki bağımlı değişken, gerçekleşen volatilitedir. (RV_t). *** % 1'de istatistiksel anlamlılığı gösterir.

Daha sonra; üç metriğe dayalı tahmin performansından elde edilen sonuçların daha fazla test edilmesi için, yani Hibrit I modelinin üstünlüğünü göstermek için, tahmin kapsayan iki test daha gerçekleştirilmiştir. Birinci test Fair ve Shiller (1989) testidir ve sonuçları Tablo 8'de gösterilmektedir. Tüm regresyonların bağımlı değişkeni gerçekleşen volatilitedir (RV_t). İlk regresyondan, her iki tahmindeki ($f_{Hybrid I}$), ($f_{Hybrid II}$) ve (f_{EGARCH}) katsayıların, sıfırdan önemli ölçüde farklı olduğu, yani bu modellerin hiçbirinin diğerini kapsamadığı tespit edilmiştir. Başka bir deyişle, her üç model de RV_t 'nin 100-haftalık ileri tahmini için bağımsız bilgiler içermektedir. Bununla birlikte, geri kalan regresyonlardan, $f_{Hybrid I}$ 'in yalnızca bireysel katsayılarının istatistiksel olarak anlamlı olduğu ortaya çıkmaktadır; bu sonuç, Hibrit I'in tahminlerinin ANN, Hibrit II ve SM'yi kapsadığını göstermektedir.

Tablo 9: Örneklem Dışı 100 Haftalık Ufuk İçin Kapsayan Tahmin (Chong ve Hendry)

Regression	Dep. var.	$f_{Hybrid I}$	f_{EGARCH}	f_{ANN}	$f_{Hybrid II}$	f_{SM}
1	$e_{Hybrid I}$		0.239			
2	e_{EGARCH}	0.772***				
3	$e_{Hybrid I}$			0.447		
4	e_{ANN}	0.482***				
5	$e_{Hybrid I}$				0.004	
6	$e_{Hybrid II}$	0.633***				
7	$e_{Hybrid I}$					0.017
8	e_{SM}	0.188***				

Dep. Var bağımlı değişkeni gösterir. *** %1'deki istatistiksel anlamlılığı gösterir.

Tablo 9, bu araştırmada kullanılan ikinci tahmini kapsayan testin, yani Chong ve Hendry (1986) testinin sonuçlarını göstermektedir. Bu tablonun ilk regresyonu ile ilgili olarak ve önemsiz katsayı ile gösterildiği gibi, f_{EGARCH} Hibrit I ve Hibrit II modellerinin gözden kaçırdığı bilgileri yakalamada başarısız olmuştur. Aynı durum f_{ANN} ve f_{SM} için de geçerlidir, yani bu tahminlerin hiçbirisi Hibrit I modelinden elde edilen tahminlere kıyasla daha fazla bilgi sağlamamaktadır. Aksine, tahmin değerlendirme ölçütlerinden türetilen Hibrit I modelinin üstünlüğü, $f_{Hybrid I}$ 'in baskınlığının, tahminin geri kalan tüm tahminleri kapsayacağını gösterecek şekilde daha da genişletilmiştir. İkinci sonuç, $f_{Hybrid I}$ 'in tahminlerin geri kalanı tarafından sunulan her şeyi ve daha fazlasını sağladığı anlamına gelmektedir.

SONUÇ

Finansal piyasalar, bu piyasalardaki paydaşlar açısından tüm ekonomiyi ilgilendiren ve paydaşların müdahale edemeyeceği, iradeleri dışında gelişen ve kontrolü mümkün olmayan sistematik riskler nedeniyle pek çok etkenin tesiri altındadırlar. “Bütün yumurtaları aynı sepete koymama” gibi bir anlayışın ifadesi olan çeşitlendirme yapmak da bütün risklerden korunmaya yetmediğinden ötürü finansal piyasalardaki aktörler, dinamik risk konusuna yoğunlaşmaya çalışarak risk yönetiminde etkinlik sağlamayı hedeflemektedirler. Bu durumda dinamik riski izlemede en fazla yararlanan araçların başında finansal enstrümanların volatilitesi gelmektedir. ARCH türü modeller, özellikle de EGARCH modelleri finansal araçların volatilitésinin tahmin edilmesinde son yıllarda öne çıkmaktadır. Her ne kadar bu modeller faydalı sonuçlar verse de değişik metotların üstünlüklerini kombine eden hibrit modellerin çok daha sağlıklı ve güvenilir neticeler vermesi hibrit yöntemlerin daha sık kullanılmasına neden olmaktadır.

Bu çalışmada Türk borsasını temsil eden Borsa İstanbul’un gösterge endeksi niteliğindeki BİST-100 endeksinin volatilitésinin modellenmesi ve tahmini araştırılmaktadır. Öncelikle Box-Jenkins metodolojisi kullanılarak otokorelasyondan kurtulmak için ARMA (2,2) modeli oluşturulmuştur. İkinci olarak, iki asimetrik GARCH modeli, önceden tanımlanmış kriter temellerine göre oluşturulmuş ve karşılaştırılmıştır. Akaike, Schwarz ve Hannan-Quinn kriterlerinin en düşük değerlerini, Log-Olasılık ise en yüksek değerini aldığı için GED dağıtılmış hatalara sahip EGARCH(1,1) modelinin en uygun model olduğu tespit edilmiştir. Modelin tahmin yeteneğinin artırılması amacıyla yapay sinir ağları kullanan iki hibrit model kurulmuştur. Hibrit 1 modeli, getiriler dışında girdilere sahip ve gecikmeli değerleri olan bir sinir ağıdır. Buna ek olarak, Hibrit 2 modeli, sinir ağı çıktısının dahil edilmesiyle geliştirilmiş ve varyans denkleminde girdi olarak yalnızca gecikmeli getirileri olan bir EGARCH modelidir.

Bu çalışmadan elde edilen bulgular, mevcut literatürle olan benzerlik ve farklılıklar açısından tartışıldığında, Kryzanowski vd. 1993, Donaldson ve Kamstra 1997, Qi ve Maddala 1999, Schittenkopf vd. 2000, Dhamija ve Bhalla 2010, Vejendla ve Enke 2013, Monfared ve Enke 2014, Çam vd. 2017, Lahmiri ‘nin (2017) çalışmalarından farklılık gösterirken, Meissner ve Kawano 2001, Bildirici ve Ersin 2009, Kristjanpoller vd. 2014, Lu vd. 2016, Bhattacharya ve Ahmed 2018, Ramos-Perez vd. 2019, Özbey ve Paksoy’un 2020 çalışmalarıyla ise benzerlik göstermektedir.

Bu çalışmanın literatüre olan katkıları olarak şunlar sayılabilir: İlk olarak, Hibrit 1 modeli zaman ufku arttıkça, örneklem içi ve örneklem dışı volatilité tahminlerinde, diğer modellere kıyasla çok daha kesin sonuçlar ortaya koymaktadır. Ayrıca, Türk borsası gibi volatilité düzeyi yüksek olan borsalarda GARCH tipi modellerle yapay sinir ağları modellerinin kombinasyonunun kullanılması sözkonusu piyasalardaki aktörlere çok daha sağlıklı tahmin yapmada faydalı olabilecektir. Bu sayede finansal piyasalardaki paydaşlar özellikle risk yönetimi açısından paha biçilmez bir bilgi kaynağı sayesinde kayıplarını minimize etme ve hatta kazanç elde edebilme olanağına kavuşabileceklerdir. Buna ek olarak, Türk borsa endeksinin kaldıraç etkisinin araştırılmasıyla ilgili olarak, Türk menkul kıymetler borsasındaki hisse senedi fiyatlarının dalgalanmasının borsa endeksinin volatilitésini üzerinde asimetrik etkilere sahip olduğu gözlenmiştir. Bu durum, Türk borsasının oynaklığının yüksek olmasının yanı sıra yatırımcılara önemli kazançlar sunabilecek bir pazar olduğu şeklinde yorumlanabilir. Yine, potansiyel yatırımcıların, GARCH tipi modeller ile yapay sinir ağları kullanmak suretiyle optimum risk-getiri bileşimini elde edebileceği yorumunu yapmak mümkündür.

ETİK BEYAN VE AÇIKLAMALAR

Etik Kurul Onay Bilgileri Beyanı

Çalışma, etik kurul izni gerektirmeyen bir çalışmadır.

Yazar Katkı Oranı Beyanı

Yazarın katkısı %100'dür.

Çıkar Çatışması Beyanı

Çalışmada potansiyel bir çıkar çatışması bulunmamaktadır.

KAYNAKÇA

- Abounoori, A. A., Naderi, E., Alikhani, N. G. & Amiri, A. (2013). *Financial Time Series Forecasting by Developing a Hybrid Intelligent System*, MPRA Paper 45615. Germany: University Library of Munich.
- Ahmed, A. E. M. & Suliman, S. Z. (2011). Modeling Stock Market Volatility Using GARCH Models Evidence from Sudan. *International Journal of Business and Social Science*, 2(23), 114-128.
- Awartani, B. M. & Corradi, V. (2005). Predicting the Volatility of the S&P500 Stock Index Via GARCH Models: The Role of Asymmetries. *International Journal of Forecasting*, 21(1), 167-183.
- Bhattacharya, S. & Ahmed, A. (2018). Forecasting Crude Oil Price Volatility in India Using a Hybrid ANN-GARCH Model. *International Journal of Business Forecasting and Marketing Intelligence*, 4(4), 446-457.
- Bildirici, M. & Ersin, Ö. Ö. (2009). Improving Forecasts of GARCH Family Models with the Artificial Neural Networks: An Application to the Daily Returns in Istanbul Stock Exchange. *Expert Systems with Applications*, 36(4), 7355-7362.
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*, 31(3), 307-327.
- Box, G. E. & Jenkins, G. M. (1976). *Time Series Analysis, Control, and Forecasting*. San Francisco, CA: Holden Day.
- Brooks, C. (2008). *Introductory Econometrics for Finance*. 2nd ed. Cambridge, England: Cambridge University Press.
- Chong, Y. Y. & Hendry, D. F. (1986). Econometric Evaluation of Linear Macro-Economic Models. *Review of Economic Studies*, 53(4): 671-690.
- Cook, S. (2012). An Historical Perspective on the Forecasting Performance of the Treasury Model: Forecasting the Growth in UK Consumers' Expenditure. *Applied Economics*, 44(5), 555-563.
- Curto, J. D., Pinto, J. C. & Tavares, G. N. (2009). Modeling Stock Markets' Volatility Using GARCH Models with Normal, Student's T And Stable Paretian Distributions. *Statistical Papers*, 50(2), 311-321.
- Çam, S., Ballı, E. & Sigeze, Ç. (2017). Petrol Fiyatlarındaki Oynaklığın ARCH/GARCH Modelleri ve Yapay Sinir Ağları Algoritması ile Tahmini. *Uluslararası Yönetim, İktisat ve İşletme Dergisi*, (ICMEB 17 Özel Sayısı), 588-597.
- Day, T. E. & Lewis, C. M. (1992). Stock Market Volatility and the Information Content of Stock Index Options. *Journal of Econometrics*, 52(1-2), 267-287.
- De Clerk, L. & Savelev, S. (2022). AI Algorithms for Fitting GARCH Parameters to Empirical Financial Data. *Physica A: Statistical Mechanics and its Applications*, 603, 127869.
- Dhamija, A. K. & Bhalla, V. K. (2010). Financial Time Series Forecasting: Comparison of Neural Networks and ARCH Models. *International Research Journal of Finance and Economics*, 49, 185-202.
- Dickey, D. A. & Fuller, W. A. (1979). Distribution of the Estimators for Autoregressive Time series with a Unit Root. *Journal of the American Statistical Association*, 74(366a), 427-431.
- Dickey, D. A. & Fuller, W. A. (1981). Likelihood Ratio Statistics for Autoregressive Time Series with a Unit Root. *Econometrica: Journal of the Econometric Society*, 49(4), 1057-1072.
- Donaldson, R. G. & Kamstra, M. (1997). An Artificial Neural Network GARCH Model for International Stock Return Volatility. *Journal of Empirical Finance*, 4(1), 17-46.
- Dritsakis, C. (2017). An Empirical Evaluation in GARCH Volatility Modeling: Evidence from the Stockholm Stock Exchange. *Journal of Mathematical Finance*, 7(02), 366-390.
- Engle, R. F. (1982). Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica: Journal of the Econometric Society*, 50(4), 987-1007.
- Engle, R. F. & Patton, A. J. (2007). *What Good Is a Volatility Model? In: Forecasting Volatility in the Financial Markets*. Netherlands: Elsevier. 47-63.
- Fahimifard, S. M., Homayounifar, M., Sabouhi, M. & Moghaddamnia, A. R. (2009). Comparison of ANFIS, ANN, GARCH and ARIMA Techniques to Exchange Rate Forecasting. *Journal of Applied Sciences*, 9(20), 3641-3651.

- Fair, R. C. & Shiller, R. J. (1989). The Informational Content of Ex Ante Forecasts. *The Review of Economics and Statistics*, 71(2), 325-331.
- Franses, P. H. & Van Dijk, D. (1996). Forecasting Stock Market Volatility Using (Non-linear) GARCH Models. *Journal of Forecasting*, 15(3), 229-235.
- Georgescu, V. & Dinucă, E. C. (2011). *Evidence of Improvement in Neural Network Based Predictability of Stock Market Indexes Through Co-Movement Entries. In: Recent Advances in Applied and Biomedical Informatics and Computational Engineering in Systems Applications. 11th WSEAS International Conference on Applied Informatics and Communications, Florence, Italy 2011, 412-417.*
- Ghiassi, M. D. K., Zimbra, D. K. & Saidane, H. (2006). Medium Term System Load Forecasting with a Dynamic Artificial Neural Network Model. *Electric Power Systems Research*, 76(5), 302-316.
- Glosten, L. R., Jagannathan, R. & Runkle, D.E. (1993). On the Relation Between the Expected Value and the Volatility of the Nominal Excess Return on Stocks. *The Journal of Finance*, 48(5), 1779-1801.
- Güreşen, E., Kayakutlu, G. & Daim, T. U. (2011). Using Artificial Neural Network Models in Stock Market Index Prediction. *Expert Systems with Applications*, 38(8), 10389-10397.
- Hajizadeh, E., Seifi, A., Zarandi, M. F. & Turksen, I. B. (2012). A Hybrid Modeling Approach for Forecasting the Volatility of S&P 500 Index Return. *Expert Systems with Applications*, 39(1), 431-436.
- Heston, S. L. (1993). A Closed-Form Solution for Options with Stochastic Volatility with Applications to Bond and Currency Options. *The Review of Financial Studies*, 6(2), 327-343.
- Jarque, C. M. & Bera, A. K. (1980). Efficient Tests for Normality, Homoscedasticity and Serial Independence of Regression Residuals. *Economics Letters*, 6(3), 255-259.
- Khan, A. U. & Gour, B. (2013). Stock Market Trends Prediction Using Neural Network Based Hybrid Model. *International Journal of Computer Science Engineering and Information Technology Research*, 3(1), 11-18.
- Ko, P. C. (2009). Option Valuation Based on the Neural Regression Model. *Expert Systems with Applications*, 36(1), 464-471.
- Koopman, S. J., Jungbacker, B. & Hol, E. (2005). Forecasting Daily Variability of the S&P 100 Stock Index Using Historical, Realised and Implied Volatility Measurements. *Journal of Empirical Finance*, 12(3), 445-475.
- Kristjanpoller, W., Fadic, A. & Minutolo, M. C. (2014). Volatility Forecast Using Hybrid Neural Network Models. *Expert Systems with Applications*, 41(5), 2437-2442.
- Kryzanowski, L., Galler, M. & Wright, D. W. (1993). Using Artificial Neural Networks to Pick Stocks. *Financial Analysts Journal*, 49(4), 21-27.
- Lahmiri, S. (2017). Modeling and Predicting Historical Volatility in Exchange Rate Markets. *Physica A: Statistical Mechanics and its Applications*, 471, 387-395.
- Lewis, N. D. (2017). *Neural Networks for Time Series Forecasting with R: An Intuitive Step by Step Blueprint for Beginners*. United States: Create Space Independent Publishing Platform.
- Liu, H. C. & Hung, J. C. (2010). Forecasting S&P-100 Stock Index Volatility: The Role of Volatility Asymmetry and Distributional Assumption in GARCH Models. *Expert Systems with Applications*, 37(7), 4928- 4934.
- Liu, W. K. & So, M. K. P. (2020). A GARCH Model with Artificial Neural Networks. *Information*, 11(10), 489.
- Ljung, G. M. & Box, G. E. (1978). On a Measure of Lack of Fit in Time Series Models. *Biometrika*, 65(2), 297-303.
- Lu, Y. K. & Perron, P. (2010). Modeling and Forecasting Stock Return Volatility Using a Random Level Shift Model. *Journal of Empirical Finance*, 17(1), 138-156.
- Lu, X., Que, D. & Cao, G. (2016). Volatility Forecast Based on the Hybrid Artificial Neural Network and GARCH-Type Models. *Procedia Computer Science*, 91, 1044-1049.
- Luo, Y. & Shah, A. (2007). A Local-Patch Based Multi-Stage Artificial Neural Network Training Procedure and Its Application to Material Characterization. *International Journal of Computational Methods*, 4(3), 439-458.

- Maciel, L. S. & Ballini, R. (2010). Neural Networks Applied to Stock Market Forecasting: An Empirical Analysis. *Journal of the Brazilian Neural Network Society*, 8(1), 3-22.
- Marcucci, J. (2005). Forecasting Stock Market Volatility with Regime-Switching GARCH Models. *Studies in Nonlinear Dynamics and Econometrics*, 9(4), 6-26.
- Meissner, G. & Kawano, N. (2001). Capturing the Volatility Smile of Options on High-Tech Stocks-a Combined GARCH Neural Network Approach. *Journal of Economics and Finance*, 25(3), 276-292.
- Merh, N., Saxena, V. P. & Pardasani, K. R. (2010). A Comparison between Hybrid Approaches of ANN and ARIMA for Indian Stock Trend Forecasting. *Business Intelligence Journal*, 3(2), 23-43.
- Metin, N., Karadağ, K. & Terzioğlu, M. K. (2020). MLP/RBF Ağ Mimarileriyle Hibrit MGARCH-ANN Model Performans Karşılaştırması: Petrol Fiyat Oynaklığı. *Ankara Hacı Bayram Veli Üniversitesi İktisadi ve İdari Bilimler Fakültesi Dergisi*, (Özel Sayı), 78-93.
- Monfared, S. A. & Enke, D. (2014). Volatility Forecasting Using a Hybrid GJR-GARCH Neural Network Model. *Precedia Computer Science*, 36, 246-253.
- Nazarian, R., Alikhani, N. G., Naderi, E. & Amiri, A. (2013). *Forecasting Stock Market Volatility: A Forecast Combination Approach*. MPRA Paper, 46786, 1-20, Germany: University Library of Munich.
- Nelson, D. B. (1991). Conditional Heteroskedasticity in Asset Returns: A New Approach. *Econometrica: Journal of the Econometric Society*, 59(2), 347-370.
- Özbey, F. & Paksoy, S. (2020). GARCH Ailesi Modelleri ve ANN Entegrasyonu ile BİST 100 Endeks Getirisinin Volatilite Tahmini. *Business and Economics Research Journal*, 11(2), 385-396.
- Pagan, A. R. & Schwert, G. W. (1990). Alternative Models for Conditional Stock Volatility. *Journal of Econometrics*, 45(1-2), 267-290.
- Pai, P. F. & Lin, C. S. (2005). A Hybrid ARIMA and Support Vector Machines Model in Stock Price Forecasting. *Omega*, 33(6), 497-505.
- Pakdaman, M., Ahmadian, A., Effati, S., Salahshour, S. & Baleanu, D. (2017). Solving Differential Equations of Fractional Order Using an Optimization Technique Based on Training Artificial Neural Network. *Applied Mathematics and Computation*, 293, 81-95.
- Qi, M. (1999). Nonlinear Predictability of Stock Returns Using Financial and Economic Variables. *Journal of Business and Economic Statistics*, 17(4), 419-429.
- Qi, M. & Maddala, G. S. (1999). Economic Factors and the Stock Market: A New Perspective. *Journal of Forecasting*, 18(3), 151-166.
- Quah, T. S. (2007). Using Neural Network for DJIA Stock Selection. *Engineering Letters*, 15(1), 3-8.
- Ramos-Perez, E., Alonso-González, P. J. & Núñez-Velázquez, J. J. (2019). Forecasting Volatility with a Stacked Model Based on a Hybridized Artificial Neural Network. *Expert Systems with Applications*, 129, 1-9.
- Roh, T. H. (2007). Forecasting the Volatility of Stock Price Index. *Expert Systems with Applications*, 33(4), 916-922.
- Sahin, S., Tolun, M. R. & Hassanpour, R. (2012). Hybrid Expert Systems: A Survey of Current Approaches and Applications. *Expert Systems with Applications*, 39(4), 4609-4617.
- Schittenkopf, C., Dorffner, G. & Dockner, E. J. (2000). Forecasting Time-Dependent Conditional Densities: A Semi Non-Parametric Neural Network Approach. *Journal of Forecasting*, 19(4), 355-374.
- Soni, S. (2011). Applications of ANNs in Stock Market Prediction: A Survey. *International Journal of Computer Science and Engineering Technology*, 2(3), 71-83.
- Tseng, C. H., Cheng, S. T., Wang, Y. H. & Peng, J. T. (2008). Artificial Neural Network Model of the Hybrid EGARCH Volatility of the Taiwan Stock Index Option Prices. *Physica A: Statistical Mechanics and its Applications*, 387(13), 3192-3200.
- Vejendla, A. & Enke, D. (2013a). Evaluation of GARCH, RNN and FNN Models for Forecasting Volatility in the Financial Markets. *IUP Journal of Financial Risk Management*, 10(1), 41-49.

- Vejendla, A. & Enke, D. (2013b). Performance Evaluation of Neural Networks and GARCH Models for Forecasting Volatility and Option Strike Prices in a Bull Call Spread Strategy. *Journal of Economic Policy and Research*, 8(2), 1-19.
- Wang, Y. H. (2009). Nonlinear Neural Network Forecasting Model for Stock Index Option Price: Hybrid GJR-GARCH Approach. *Expert Systems with Applications*, 36(1), 564-570.
- Wei, W. (2002). Forecasting Stock Market Volatility with Non-Linear GARCH Models: A Case for China. *Applied Economics Letters*, 9(3), 163-166.
- Wei, L. Y., Chen, T. L. & Ho, T. H. (2011). A Hybrid Model Based on Adaptive-Network-Based Fuzzy Inference System to Forecast Taiwan Stock Market. *Expert Systems with Applications*, 38(11), 13625-13631.
- <https://www.matriksdata.com/website/>, Eriřim tarihi: 19.12.2022.