

19. BÖLÜM / CHAPTER 19

GARCH, YAPAY SİNİR AĞLARI VE DESTEK VEKTÖR REGRESYONU YÖNTEMLERİNİN KARŞILAŞTIRILMASI: BİST HİZMETLER ENDEKS GETİRİSİ ÖRNEĞİ

COMPARISON OF GARCH, ARTIFICIAL NEURAL NETWORKS, AND SUPPORT VECTOR REGRESSION METHODS: THE CASE OF THE BIST SERVICES INDEX RETURN

N. Melis ESENYEL İÇEN*

*Arş. Gör., İstanbul Üniversitesi, İktisat Fakültesi, Ekonometri Bölümü, İstanbul, Türkiye
E-mail: melis.esenyel@istanbul.edu.tr

DOI: 10.26650/B/SS10.2021.013.19

ÖZ

Hisse senedi fiyatlarındaki oynaklığın tahmin edilmesi, hem bireysel hem kurumsal düzeyde yatırımcılar için önemini korumaktadır. Bu bakımdan uygun tahmin yönteminin belirlenmesi uzun zamandır araştırmacıların ve yatırımcıların üzerinde durduğu bir konu olmuştur. Çalışmada, klasik oynaklık modelleri ve yapay zeka modelleri kullanılarak Borsa İstanbul hizmetler endeksi getirisinin öngörü performansının karşılaştırılması amaçlanmıştır. Klasik ve yapay zeka modellerine ek olarak hibrit modeller de oluşturulmuştur ve hibrit modellerin öngörü performansını artırıp artırmadığı incelenmiştir. Analize konu olan hizmetler sektörünün önemi, gelişmiş ve gelişmekte olan ülkelerde tarım ve sanayi sektörlerine kıyasla daha fazla gelişme göstermesidir. Bunun yanı sıra hizmet sektörü sektörel bazda yüksek bir paya sahip olduğundan ülkelerin gelişmişlik düzeyi ile alakalı olarak görülmektedir. Dolayısıyla hizmetler endeksinin modellenmesi ve tahmini önemli olmaktadır. Analizde kullanılan Borsa İstanbul hizmetler endeksi verileri TCMB Elektronik Veri Dağıtım Sisteminden alınmış olup, 05.01.2009-13.11.2020 dönemini kapsayan günlük frekanstadır. Analiz sonucuna göre oluşturulan on model içerisinde öngörü performansı en yüksek modellerin hibrit modellerden DVR-EGARCH ve ELM-EGARCH olduğu görülmüştür.

Anahtar Kelimeler: Borsa İstanbul Hizmetler, GARCH modelleri, Yapay Sinir Ağları, Hızlı Öğrenen Makine, Destek Vektör Regresyonu

Extended Abstract

Measuring the volatility in stock prices is an important research concern at both individual and institutional levels. Individuals and businesses want to know the fluctuation of prices to avoid portfolio losses and to make profitable investments. Countries also try to understand the volatility in stock prices to determine investment policies at the international level. Consequently, establishing the appropriate estimation method has long been a topic of focus for researchers and investors alike.

Methods used in forecasting stock returns are generally classified as linear and nonlinear models. Linear models include autoregressive integrated moving average, exponential smoothing, and generalized autoregressive conditional heteroskedasticity (GARCH), among others. These models are mainly based on an assumption of linearity between variables that are normally distributed. Most of the studies that attempt to reveal the relationship between stock returns and financial and economic variables are based on simple linear regression assumptions. However, no evidence supports the assumption that this relationship is entirely linear. The significance of residual variance and the ability to explain this residual variance with nonlinear models makes it possible to obtain more reliable predictions using nonlinear models. Nonlinear models include those based on artificial intelligence, such as artificial neural networks (ANN), support vector machines, genetic algorithms, and particle swarm optimization. The assumption of linearity and normality may not be provided in the modeling of stock price movements. For this reason, artificial intelligence methods that have no restrictive assumptions have been recommended in the literature. These methods can also identify nonlinear structures, and have been shown to perform better empirically than statistical methods.

This study aims to compare the forecasting performance of the Borsa Istanbul (BIST) services index return applying classical volatility and artificial intelligence models. In addition to these models, hybrid models were also created to investigate whether hybrid models increase forecasting performance. The GARCH and exponential generalized autoregressive conditional heteroskedasticity (EGARCH), which are linear volatility models, as well as ANN and support vector regression (SVR), which are nonlinear models, will be used to predict stock returns. Hybrid models will also be created by combining ANN and SVR with GARCH and EGARCH models.

The services index is the stock market index calculated by considering changes in the stock prices of only services sector companies traded in the national market. There are 65

companies traded in the BIST services sector, and approximately 38% of these companies are in the “wholesale and retail trade, restaurants, and hotels” sector. The importance of the services sector is that it is more established in both developed and developing countries, as opposed to agricultural and industrial sectors. In addition, as the service sector has a high share on a sectoral basis, it is seen as related to a country’s development level, making the modeling and forecasting of the BIST services index an important consideration. The daily data used in the analysis is obtained from the Central Bank Electronic Data Delivery System covering the period 05.01.2009–13.11.2020. The results indicate that among the 10 models created and applied, those with the highest forecasting performance are the hybrid models SVR-EGARCH and extreme learning machine-EGARCH.

Keywords: Borsa Istanbul Services, GARCH models, Artificial Neural Networks, Extreme Learning Machine, Support Vector Regression

1. Giriş

Oynaklığın modellenmesi ve tahmin edilmesi, finansal piyasalarda önemini korumaktadır. Yatırım, opsiyon fiyatlandırması ve risk yönetiminde oynaklığın önemini analiz eden kapsamlı araştırmalar uzun zamandır yapılmaktadır. Oynaklığın yüksek olması finansal varlığın riskli olduğunu gösterdiğinden, varlık getirisi oynaklığının doğru tahmini yatırım riskini değerlendirmek için çok önemlidir.

Hisse senedi piyasaları birbiriyle oldukça ilişkili birçok faktörden etkilenir. Bu faktörler; 1) faiz oranları, döviz kurları, parasal büyüme oranları, emtia fiyatları ve genel ekonomik koşullar gibi ekonomik değişkenler; 2) endüstriyel üretimin büyüme oranları ve tüketici fiyatları gibi sektöre özgü değişkenler; 3) şirket politikalarındaki, gelir tablolarındaki ve temettü getirilerindeki değişiklikler gibi şirkete özgü değişkenler; 4) yatırımcıların beklentileri ve kurumsal yatırımcıların tercihleri gibi yatırımcıların psikolojik değişkenleri; ve 5) önemli siyasi olayların oluşumu ve serbest bırakılması gibi politik değişkenler (Enke ve Thawornwong, 2005; Wang, Wang, Zhang, ve Guo, 2011) olarak sıralanabilir. Bu faktörlerin her biri çok karmaşık bir şekilde etkileşime girmektedir (Yao, Tan, ve Poh, 1999). Fama (1970) tarafından ortaya konulan etkin piyasa hipotezine göre, hisse senedi fiyatının en iyi tahmini son fiyattır, çünkü ilgili tüm bilgiler ortaya çıktığında hemen fiyatlara yansıtılmaktadır. Mevcut hisse senedi değerleri o anda piyasadaki tüm bilgileri yansıttığından halk bu bilgilere dayanarak başarılı alım satım yapamayacaktır. Dolayısıyla etkin piyasa hipotezi, borsa hareketlerinin anlaşılmasını ve tahmin edilmesini zorlaştırmaktadır. Ancak bazı araştırmacılar, çeşitli psikolojik faktörler sebebiyle, piyasaların etkin olmadığını öne sürmüşlerdir (Jensen, 1978). Dolayısıyla hisse senedi fiyatları vb. finansal değişkenlerin tahmin edilebilir olduğu düşünülmektedir (Zhong ve Enke, 2017).

Mevcut bilgi ile hisse senedi getirileri arasındaki ilişkiyi ortaya koymaya çalışan çalışmaların çoğu, basit doğrusal regresyon varsayımlarına dayanmaktadır. Ancak hisse senedi getirileri ile finansal ve ekonomik değişkenler arasındaki ilişkinin tamamen doğrusal olduğu varsayımını destekleyen hiçbir kanıt bulunmamaktadır. Regresyon denkleminde elde edilen tahmin ile gerçek hisse senedi getirisi arasındaki farka dayanan kalıntı varyansının anlamlı olması ve bu kalıntı varyansının doğrusal olmayan modeller ile açıklanabilmesi, doğrusal olmayan modeller kullanılarak daha güvenilir tahminler elde edilmesini mümkün kılmaktadır (Priestley, 1988; Mills, 1991). Bununla birlikte hisse senedi fiyatları esasen dinamik, doğrusal ve parametrik değildir ve doğası gereği kaotiktir. Bu, yatırımcıların durağan olmayan, gürültülü ve sık sık yapısal kırılmalar yaşayan zaman serilerini ele almaları gerektiği anlamına gelmektedir (Oh ve Kim, 2002; Wang, 2003).

Hisse senedi getirilerinin tahmininde kullanılan yöntemler genel olarak doğrusal modeller ve doğrusal olmayan modeller olarak sınıflandırılır. Doğrusal modeller, otoregresif entegre hareketli ortalama (ARIMA), üstel düzeltme, genelleştirilmiş otoregresif koşullu heteroskedasite (GARCH) vb. modelleri içermektedir (Durham, 2007). Bu modeller, esas olarak normal dağılım gösteren değişkenler arasındaki doğrusallık varsayımına dayanmaktadır. Doğrusal olmayan modeller ise, yapay sinir ağları (YSA) (Chen, 1994), destek vektör makineleri (DVM) (Burges, 1998) (Huang, Nakamori, ve Wang, 2005), genetik algoritmalar ve parçacık sürüsü optimizasyonu (Majhi vd., 2008) gibi yapay zekaya dayanan modelleri içermektedir. Bilindiği gibi hisse senedi fiyat hareketlerinin modellenmesinde doğrusallık ve normallik varsayımı sağlanmayabilir. Bu sebeple araştırmacılar, kısıtlayıcı varsayımların olmadığı, doğrusal olmayan yapıyı yakalayabilen ve deneysel olarak istatistiksel yöntemlerden daha iyi performans gösterdiği ortaya konulan yapay zeka yöntemlerinin kullanılmasını önermektedir (Hansen ve Nelson, 2002; Zhang, 2003; Enke ve Thawornwong, 2005; Ture ve Kurt, 2006 vd.)

Bu çalışmada, Borsa İstanbul (BİST) hizmetler endeksi (XUHIZ) getirisinin oynaklığının modellenmesi ve tahmin edilmesi amaçlanmaktadır. BİST hizmetler sektöründe işlem gören 65 işletme bulunmaktadır¹. Bu işletmelerin yaklaşık %38'i "toptan ve perakende ticaret, lokantalar ve oteller" sektöründe, %15'i "elektrik, gaz ve su" ve %15'i ise "ulaştırma, depolama ve haberleşme" sektöründe bulunmaktadır. En düşük oran ise yaklaşık %3 ile "mesleki, bilimsel ve teknik faaliyetler", "idari ve destek hizmet faaliyetleri" ve "gayrimenkul faaliyetleri" sektörlerine aittir. Hizmetler endeksinin seçilmesinin nedeni, dinamik bir yapıya sahip olan hizmet sektörünün, hem gelişmiş hem gelişmekte olan ülkelerde, sanayi ve tarım sektöründen daha fazla gelişme kaydetmesidir. Ayrıca hizmet sektörünün diğer sektörler içindeki payı düşünüldüğünde, ülkelerin gelişmişlik düzeyi ile de yakın ilişki içerisinde. Dolayısıyla hizmetler endeksinin modellenmesi ve tahmini önemli olmaktadır. Bu motivasyonla, doğrusal oynaklık modellerinden GARCH (Bollerslev, 1986) ve EGARCH (Nelson, 1991), doğrusal olmayan modellerden ise yapay sinir ağları (YSA) ve destek vektör regresyonu (DVR) hisse senedi getirilerini tahmin etmek için kullanılacaktır. Bunun yanı sıra YSA ve DVR ile GARCH ve EGARCH modelleri birleştirilerek, hibrit modeller de oluşturulacaktır.

2. Yöntem ve Bulgular

Çalışmada kullanılan XUHIZ endeks verileri Türkiye Cumhuriyet Merkez Bankası Elektronik Veri Dağıtım Sistemi'nden elde edilmiştir. 05.01.2009-13.11.2020 dönemini kapsayan veriler günlük frekanstadır. Endeks ve getiri serilerine ait tanımlayıcı istatistikler Tablo 1'de özetlenmiştir.

1 Hizmetler endeksindeki işletmeler EK' teki tabloda belirtilmiştir.


Tablo 1
BİST hizmet endeksi ve getirisinin tanımlayıcı istatistikleri

	Fiyat	Getiri
Gözlem sayısı	2977	2976
Ortalama	541.82	0.05
Medyan	537.31	0.10
Maksimum	999.75	6.20
Minimum	212.53	-9.70
Standart sapma	166.55	1.29
ADF	-2.53 (0.32)	-53.32 (0.00)
Çarpıklık	0.35	-0.66
Baskınlık	2.64	6.91
Jarque-Bera	74.32 (0.00)	2116.38 (0.00)

Endeks, Denklem (1) kullanılarak getiri serisine dönüştürülmüştür.

$$y_t = \ln\left(\frac{p_t}{p_{t-1}}\right) * 100 \quad (1)$$

Burada p_t , hisse senedi fiyatlarını, y_t ise hisse senedi getirisini temsil etmektedir. Endeksler ve getirilerine ait grafikler sırasıyla Şekil 1’de verilmiştir. Fiyatların yıllar itibariyle artış eğiliminde olduğu görülmektedir. Ayrıca getiri serisinin seyrine bakıldığında küçük şokların küçük şokları, büyük şokların ise büyük şokları takip ettiği görülmektedir. Bu durum oynaklık kümelenmesine işaret etmektedir.



Şekil 1. BİST Hizmetler Endeksi ve Getirisi

Çalışmada kullanılan hisse senedi getirisini için toplam 2976 adet gözlem bulunmaktadır. Veri kümesi eğitim (%95), doğrulama (%2.5) ve test (%2.5) olarak üçe ayrılmıştır (Hossain

ve Nasser, 2011). Modellerin belirlenmesi için eğitim kümesi, parametrelerin ayarlanması için doğrulama kümesi ve modellerin öngörü performansını değerlendirmek için de test kümesi kullanılmıştır. Öngörü performansının değerlendirilmesi için ise hata ölçüm kriterlerinden, ortalama hata karesi (mean square error-MSE) ve ortalama mutlak hata (mean absolute error-MAE) kullanılmıştır (Tay ve Cao, 2001).

2.1. GARCH Modelleri

Döviz kuru, hisse senedi vb. finansal zaman serilerini tahmin etmek için oluşturulan ekonometrik modellerin genel bir sorunu, hata terimlerinin heteroskedastik olmasıdır. Klasik yöntemlerle tahmin gerçekleştirildiğinde parametrelerin etkinliği bozulacağından Engle (1982) Otoregresif Koşullu Heteroskedasite (ARCH) modelini önermiştir. Sonraları Bollerslev (1986) ve Nelson (1991), Genelleştirilmiş Otoregresif Koşullu Heteroskedasite (GARCH) ve Üstel GARCH (EGARCH) modellerini ortaya koyarak ARCH modelini geliştirmişlerdir. Denklem (2) ARMA(m,n) modelini göstermek üzere, ARMA(m,n)-GARCH(p,q) ve ARMA(m,n)-EGARCH(p,q) modelleri sırasıyla Denklem (3) ve Denklem (4)'teki gibi ifade edilmektedir.

$$Y_t = \mu + \sum_{i=1}^m \phi_i Y_{t-i} + \sum_{j=1}^n \theta_j \varepsilon_{t-j} + \varepsilon_t, \quad \varepsilon_t \sim N(0, \sigma_t^2) \quad (2)$$

$$\sigma_t^2 = \omega + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2 \quad (3)$$

$$\varepsilon_t = z_t \sigma_t, \quad z_t \sim N(0,1)$$

$$\ln(\sigma_t^2) = \omega + \sum_{i=1}^p \alpha_i \left(\frac{|\varepsilon_{t-i}|}{\sigma_{t-i}} - E\left(\frac{|\varepsilon_{t-i}|}{\sigma_{t-i}}\right) \right) + \sum_{j=1}^p \beta_j \ln(\sigma_{t-j}^2) + \sum_{k=1}^r \gamma_k \frac{\varepsilon_{t-k}}{\sigma_{t-k}} \quad (4)$$

Burada ϕ_i ve θ_j sırasıyla AR ve MA terimlerinin katsayısı, σ_t^2 , koşullu varyans, γ_k ; kaldıraç etkisini gösteren katsayıdır.


Öncelikle getiri serisinin ARMA modelleri kurulmuş ve parametre kısıtlarını sağlayan modeller arasından AIC ve SC bilgi kriterleri yardımıyla *ARMA(2,2)* modeli belirlenmiştir. Ardından *ARMA(2,2)* modeline ARCH-LM testi yapılmıştır. Elde edilen bulgulara göre ARCH etkisinin olduğuna karar verilmiştir. Böylece getiri serisi için GARCH modellerinin kurulması uygun bulunmuştur. Bunun yanı sıra çalışmada, GARCH modelleri farklı dağılımlar kullanılarak (normal-Gaussian, genelleştirilmiş hata dağılımı-GED) tahmin edilmiştir. GARCH model sonuçları Tablo 2'de gösterilmiştir.

Tablo 2


BIST Hizmetler Endeksi Getirisi İçin Parametrik Modellerin Sonuçları

	GARCH	EGARCH	GARCH	EGARCH
	Normal Dağılım		GED Dağılımı	
μ	0.0604**	0.0561**	0.1047*	0.0834*
ϕ_1	1.2777*	-1.3962*	1.3526*	-0.4971*
ϕ_2	-0.8605*	-0.8430*	-0.9946*	-0.9480*
θ_1	-1.2657*	1.4063*	-1.3531*	0.5087*
θ_2	0.8606*	0.8572*	0.9971*	0.9466*
ω	0.9452*	-0.1044*	0.1035*	-0.0930*
α	0.0214**	0.1769*	0.0964*	0.1486*
β	0.4714*	0.9226*	0.0263*	0.9404*
γ	-	-0.1036*	-	-0.0914*
$\alpha + \beta$	0.4928	-	0.9356	-


Not: “*”, “**” ve “***” sembolleri sırasıyla %1, %5 ve %10 anlamlılık düzeylerini ifade etmektedir.




Şekil 2. GARCH-N modelinden elde edilen getiri tahminlerinin gerçek değerler ile karşılaştırılması



Şekil 3. GARCH-GED modelinden elde edilen getiri tahminlerinin gerçek değerler ile karşılaştırılması



Şekil 4. EGARCH-N modelinden elde edilen getiri tahminlerinin gerçek değerler ile karşılaştırılması




Şekil 5. EGARCH-GED modelinden elde edilen getiri tahminlerinin gerçek değerlerle karşılaştırılması

GARCH-N, GARCH-GED, EGARCH-N ve EGARCH-GED modellerinden elde edilen tahminler ile gerçek değerlerin karşılaştırılması sırasıyla Şekil 2, Şekil 3, Şekil 4 ve Şekil 5 ile verilmiştir. Mavi çizgiler gözlemlenen getiri değerlerini ve kırmızı çizgiler tahmin edilen değerleri göstermek üzere, tam örtüşmenin sağlanamadığı görülmektedir. Grafikselleştirildiğinde, öngörü başarısının yetersiz olduğu söylenebilir.

2.2. YSA Modeli

YSA modelinde Hızlı Öğrenen Makine (Extreme Learning Machine-ELM) öğrenme algoritması kullanılmıştır (Huang vd. (2006)). ELM algoritması tek gizli katmanlı yapay sinir ağlarını eğitmek üzere geliştirilmiş olup, gradyal tabanlı öğrenme algoritmalarına kıyasla çok hızlı olduğundan dolayı seçilmiştir. Çalışmada girdi katmanı, gizli katman ve çıktı katmanı olacak şekilde üç katmanlı bir ağ yapısı oluşturulmuştur. Getirinin gecikmeleriyle kurulan modelde en az hatayı veren gecikme sayısı dikkate alınmıştır ve girdi katmanındaki nöron sayısına karar verilmiştir. Benzer şekilde gizli katmandaki nöron sayısını belirlemek için, doğrulama kümesi üzerinde 1000 iterasyon yapılmış ve en az hatayı veren nöron sayısı dikkate alınmıştır. Çıktı katmanındaki nöron sayısı ise 1 olarak belirlenmiştir. XUHIZ getiri serisi için yapılan denemeler sonucunda MSE hatasını en küçükleyen pozitif doğrusal fonksiyon (poslin), aktivasyon fonksiyonu olarak seçilmiştir. Yapılan 1000 iterasyon sonucu, doğrulama kümesi üzerinde en az MSE değerini veren gizli katmandaki nöron sayısı 12 olarak

belirlenmiştir ve $ELM(5-12-1)$ modeli uygun bulunmuştur². Tahmin edilen değerlerin gerçek değerler ile karşılaştırılması grafikleri Şekil 6 ile verilmiştir.



Şekil 6. ELM modelinden elde edilen getiri tahminlerinin gerçek değerler ile karşılaştırılması

Şekil 6 incelendiğinde, GARCH modellerine benzer şekilde, grafiksel olarak bakıldığında öngörü başarısının yetersiz olduğu söylenebilir.

2.3. DVR Modeli


Bu çalışmada DVR modelinin tahmin edilmesi için e1071 adlı R paketi kullanılmıştır. Bu paket Chih-Chung ve Chih-Jen Lin tarafından geliştirilen C++ dilinde yazılmış LibSvm paketine R için bir arayüz sağlamaktadır. Libsvm, literatürde en çok kullanılan DVM Kütüphanesi olması bakımından seçilmiştir.

DVR’de doğru ve güvenilir sonuçlar elde edebilmek için modelin parametrelerinin ve kernel tipinin seçimi çok önemlidir. Bu sebeple uygun DVR modelini bulmak için birçok deneme yapılmış ve minimum hatayı veren parametreler ve kernel seçilmiştir. Libsvm’de yer alan kernel tiplerinden olan doğrusal, sigmoid, polinomiyal ve radyal tabanlı fonksiyon, denemelerle uygun kernelin belirlenmesinde kullanılmıştır. Bu denemelerin sonucunda doğrusal kernel fonksiyonu seçilmiştir.

Uygun hata tolerans parametresi ve cost parametresinin belirlenmesi için paralel hesaplama paketi kullanılmıştır. Epsilon (ϵ) ve cost (C) parametresinin seçimi, doğrulama kümesi üzerinde

2 $ELM(a-b-c)$ modelinde a; girdi katmanındaki, b; gizli katmandaki ve c; çıktı katmanındaki nöron sayısını temsil etmektedir.

en küçük ortalama hata karesine sahip değeri bulmak için sırasıyla [0.01,0.1] ve [0.05,10] aralığında DVR eğitilerek belirlenmiştir. Girdi kümesi getirilerin gecikmeli değerleriyle oluşturulacağından uygun gecikme sayısının belirlenmesi için gecikme sayısı 1'den başlayarak modeller kurulmuştur. YSA modeline benzer şekilde gecikme sayısının belirlenmesinde MSE değeri dikkate alınmıştır. XUHIZ getirisi için $DVR(3-0.09-3)$ modeli uygun bulunmuştur³. Tahmin edilen değerlerin gerçek değerler ile karşılaştırılması grafikleri Şekil 7 ile verilmiştir.



Şekil 7. DVR modelinden elde edilen getiri tahminleri ile gerçek değerlerin karşılaştırılması

Şekil 7 incelendiğinde, GARCH modelleri ve ELM'ye benzer şekilde, grafiksel olarak bakıldığında öngörü başarısının yetersiz olduğu söylenebilir.

2.4. ELM Oynaklık Modelleri

Çalışmada ELM-GARCH(1,1) oynaklık modelinin ağa önceden tanıtılması gereken girdileri σ_{t-1}^2 ve ε_{t-1}^2 şeklindedir. Koşullu varyans değeri, getirilerin karesinin hareketli ortalamasından $(\hat{\sigma}_t^2 = 1/5 \sum_{k=0}^4 R_{t-k}^2)$, şokların karesinin değeri, getirilerin karesinden ($R_t^2 = \varepsilon_t^2$) elde edilmiştir. Buradan hareketle ELM-GARCH(1,1) modeli,

$$\hat{\sigma}_t^2 = h(\hat{\sigma}_{t-1}^2, R_{t-1}^2)$$

şeklindedir.


3 $DVR(d-e-f)$ modelinde d; girdi sayısını, e; ε parametresini, f ise $Cost$ parametresini temsil etmektedir.

ELM-EGARCH(1,1) oynaklık modelinin girdileri $\ln(\hat{\sigma}_{t-1}^2)$, $\left[\frac{|R_{t-1}|}{\hat{\sigma}_{t-1}} - E\left(\frac{|R_{t-1}|}{\hat{\sigma}_{t-1}} \right) \right]$ ve $\frac{|R_{t-1}|}{\hat{\sigma}_{t-1}}$ olup, ELM-EGARCH(1,1) modeli,


$$\ln(\hat{\sigma}_t^2) = h \left(\ln(\hat{\sigma}_{t-1}^2), \left[\frac{|R_{t-1}|}{\hat{\sigma}_{t-1}} - E\left(\frac{|R_{t-1}|}{\hat{\sigma}_{t-1}} \right) \right], \frac{|R_{t-1}|}{\hat{\sigma}_{t-1}} \right)$$

şeklindedir (Pérez-Cruz vd., 2003; Ou & Wang, 2010).

Getiri serisinin ELM-GARCH ve ELM-EGARCH modelleri için yine üç katmanlı bir ağ yapısı belirlenmiştir. Girdi katmanındaki nöron sayısı modele dahil edilen bağımsız değişken sayısı kadar ve çıktı katmanındaki nöron sayısı bir olarak belirlenmiştir. Gizli katmandaki nöron sayısının belirlenmesi için ise YSA'daki sürecin aynısı kullanılmıştır. Aktivasyon fonksiyonu olarak ELM-GARCH modeli için türevlenebilir pozitif doğrusal fonksiyon, ELM-EGARCH modeli için ise radyal tabanlı fonksiyon, seçilmiştir. Sonuç olarak uygun modeller, *ELM-GARCH(2-12-1)* ve *ELM-EGARCH(3-7-1)* olarak bulunmuştur. ELM-GARCH ve ELM-EGARCH modellerinin gerçek ile tahmin edilen değerlerinin karşılaştırılması, sırasıyla Şekil 8 ve Şekil 9'da gösterilmiştir.



Şekil 8. ELM-GARCH modelinden elde edilen tahmin değerleri ile gerçek değerlerin karşılaştırılması

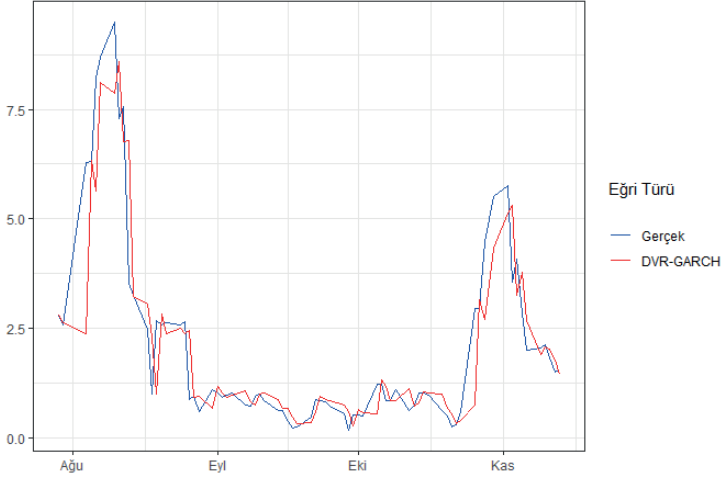


Şekil 9. ELM-EGARCH modelinden elde edilen tahmin değerleri ile gerçek değerlerin karşılaştırılması

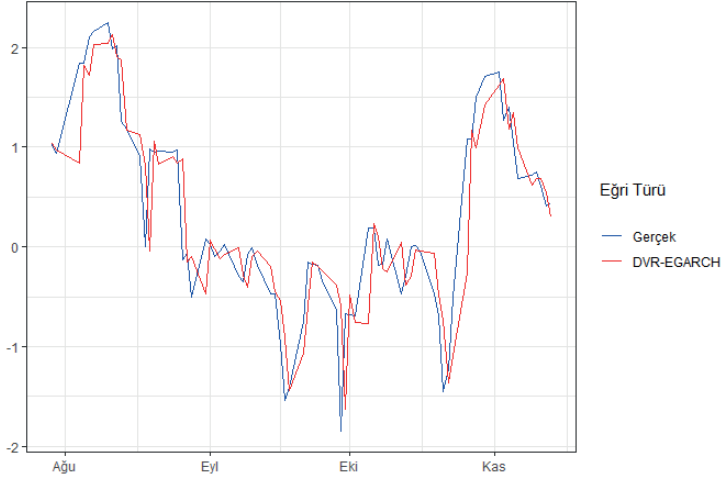
Şekil 8 ve 9 incelendiğinde ELM-GARCH/EGARCH modellerinin, GARCH, ELM ve DVR modellerine kıyasla tahmin başarısının daha iyi olduğu söylenebilir.

2.5. DVR Oynaklık Modelleri

Çalışmamızda DVR-GARCH ve DVR-EGARCH oynaklık modellerinin kurulmasında e1071 adlı R paketi kullanılmıştır. Kernel fonksiyonu olarak DVR-GARCH modeli için doğrusal fonksiyon, DVR-EGARCH modeli için ise radyal tabanlı fonksiyon seçilmiştir. Yapılan denemeler sonucunda XUHIZ getirisi için $DVR-GARCH(2-0.1-0.05)$ ve $DVR-EGARCH(3-0.1-9.85)$ modelleri uygun bulunmuştur. DVR-GARCH ve DVR-EGARCH modelleri için tahmin ile gerçek değerlerin karşılaştırılması sırasıyla, Şekil 10 ve Şekil 11 ile verilmiştir.



Şekil 10. DVR-GARCH modelinden elde edilen tahmin değerleri ile gerçek değerlerin karşılaştırılması



Şekil 11. DVR-EGARCH modelinden elde edilen tahmin değerleri ile gerçek değerlerin karşılaştırılması

Şekil 10 ve 11 incelendiğinde ELM-GARCH/EGARCH modellerinin, GARCH, ELM ve DVR modellerine kıyasla tahmin başarısının daha iyi olduğu söylenebilir.

2.6. Modellerin Karşılaştırılması

Çalışmada XUHIZ getirisi için kurulan on modelin öngörü hataları farklı hata ölçüm kriterlerine göre Tablo 3'te verilmiştir.

Tablo 3

Modellerin hata ölçüm kriterlerine göre karşılaştırılması

Model	MSE	S	MAE	S	TS
<i>GARCH(1,1)-N</i>	1.994573	8	1.055454	7	15
<i>GARCH(1,1)-GED</i>	2.006435	10	1.058482	9	19
<i>EGARCH(1,1)-N</i>	1.995055	9	1.057166	8	17
<i>EGARCH(1,1)-GED</i>	1.993202	7	1.060299	10	17
<i>ELM</i>	1.894555	5	1.044753	5	10
<i>DVR</i>	1.980164	6	1.054494	6	12
<i>ELM-GARCH</i>	0.830663	3	0.547258	4	7
<i>ELM-EGARCH</i>	0.186123	1	0.298329	2	3
<i>DVR-GARCH</i>	0.842789	4	0.520189	3	7
<i>DVR-EGARCH</i>	0.186772	2	0.296327	1	3

Not: S: hata ölçüm kriterine göre sıralamayı ve TS: toplam skoru göstermektedir.

Modellerin hata ölçüm kriterlerine göre aldıkları skor değerleri (S) 1-10 arası puanlandırılmıştır. Bu puanlar modellerin sıra numaralarını göstermektedir ve 1 en iyi skoru, 10 ise en kötü skoru ifade etmektedir. Kullanılan iki hata ölçüm kriterine göre TS hesaplanmış ve modellerin karşılaştırılması amaçlanmıştır. Tablo 3 incelendiğinde en düşük TS değerine sahip modellerin DVR-EGARCH ve ELM-EGARCH olduğu görülmektedir. DVR-GARCH ve ELM-GARCH modelleri ise onları takip etmektedir. En düşük skoru ise GARCH-GED, EGARCH-GED ve EGARCH-N modelleri almışlardır. Buradan hareketle 10 model içerisinde XUHIZ getiri serisinin tahmininde, ele alınan dönem içerisinde, hibrit modellerin öngörü performansının GARCH modellerinden daha iyi olduğu söylenebilir.

3. Sonuç

Genel olarak hisse senedi fiyatlarındaki oynaklığın ölçülmesi hem bireysel hem de kurumsal düzeyde önemli bir araştırma alanı oluşturmaktadır. Bireyler ve işletmeler portföylerinde zarara uğramamak ve karlı yatırımlar yapmak için fiyatlardaki dalgalanmayı bilmek isterler. Hatta ülkeler uluslararası düzeyde yatırım politikalarını belirlemek için hisse senedi fiyatlarındaki dalgalanmayı anlamaya çalışırlar. Bu bakımdan uygun tahmin yönteminin belirlenmesi uzun zamandır araştırmacıların ve yatırımcıların üzerinde durduğu bir konu olmuştur.

Çalışmada GARCH modellerinin tahmin gücünün artırılması ve doğrusal olmayan yapı ile oynaklığa dikkat çekerek XUHIZ endeks getirisinin incelenmesi amaçlanmıştır. Endeks getirisinin güçlü leptokurtik dağılım gösterdiği bu nedenle GARCH tipi modellerin gerekli

olduğu gösterilmiştir. Zamanla değişen oynaklığın yanı sıra doğrusal olmayan yapı da dikkate alınarak yapay zeka tabanlı modellerin kullanılması önerilmiştir.

Çalışmada kullanılan XUHIZ endeksine ait günlük veriler TCMB EVDS'den elde edilmiştir ve endeks, logaritmik getiri serisine çevrilmiştir. Bu getiri serisinin tahmini için klasik oynaklık modellerinden GARCH ve EGARCH modelleri kullanılmıştır. Klasik yöntemler için hata terimlerinin normal ve GED dağılımına sahip olduğu durumlar dikkate alınarak iki farklı tahmin yapılmıştır. Yapay zekâ yöntemlerinden YSA/ELM ve DVR modelleri kullanılmıştır. Ayrıca bu iki yöntem birleştirilerek ELM-GARCH, ELM-EGARCH, DVR-GARCH ve DVR-EGARCH hibrit modelleri oluşturulmuştur.

Klasik istatistiksel modellerden olan GARCH ve EGARCH kısa hafızalı modellerdir. Bunun anlamı, modellerin uzun dönemli tahminler için uygun olmamasıdır. Veri kümesinde test kümesinin, eğitim kümesine göre çok daha küçük tutulmasının sebebi budur. Böylelikle bu yöntemlerin uzun dönemli tahminlerdeki eksikliği azaltılmaya çalışılmıştır.

Modellerin tahmin performansını karşılaştırmak için hata ölçüm kriterlerinden yararlanılmıştır. Elde edilen bulgulara göre, XUHIZ getirisi için hem yapay zeka tekniklerinden olan YSA ve DVR'nin hem de ELM-GARCH, ELM-EGARCH, DVR-GARCH ve DVR-EGARCH hibrit modellerinin GARCH ve EGARCH modellerine kıyasla, daha az hatayla tahmin yaptığı görülmüştür. Bu sonuca göre, ele alınan dönem içinde yapay zeka ve hibrit modellerinin GARCH ve EGARCH modellerine kıyasla daha üstün olduğu söylenebilir. Hata ölçüm kriterlerinin yanı sıra gerçek ve tahmin edilen serilerin grafiklerine bakıldığında da bu tekniklerin oynaklık kümelenmesini daha iyi yansıttığı görülmektedir. Çalışmada kullanılan hibrit ve yapay zeka modellerinin ele alınan dönem için BIST XUHIZ endeks getirisini modellemede, GARCH modellerine göre daha üstün performans sergilediği görülmektedir.

Kaynakça/References

- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3), 307–327. [https://doi.org/http://dx.doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/http://dx.doi.org/10.1016/0304-4076(86)90063-1)
- Burges, C. J. C. (1998). A tutorial on support vector machines for pattern recognition. *Data mining and knowledge discovery*, 2(2), 121–167.
- Chen, C. H. (1994). Neural networks for financial market prediction. İçinde *Proceedings of 1994 IEEE International Conference on Neural Networks (ICNN'94)* (C. 2, ss. 1199–1202).
- Durham, G. B. (2007). SV mixture models with application to S&P 500 index returns. *Journal of Financial Economics*, 85(3), 822–856.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation. *Econometrica: Journal of the Econometric Society*, 987–1007.
- Enke, D., & Thawornwong, S. (2005). The use of data mining and neural networks for forecasting stock market returns. *Expert Systems with applications*, 29(4), 927–940.

- Fama, E. F. (1970). Efficient capital markets: A review of theory and empirical work. *The Journal of Finance*, 25(2), 383–417.
- Hansen, J. V., & Nelson, R. D. (2002). Data mining of time series using stacked generalizers. *Neurocomputing*, 43(1–4), 173–184.
- Hossain, A., & Nasser, M. (2011). Comparison of the finite mixture of ARMA-GARCH, back propagation neural networks and support-vector machines in forecasting financial returns. *Journal of Applied Statistics*, 38(3), 533–551. <https://doi.org/10.1080/02664760903521435>
- Huang, W., Nakamori, Y., & Wang, S.-Y. (2005). Forecasting stock market movement direction with support vector machine. *Computers & operations research*, 32(10), 2513–2522.
- Jensen, M. C. (1978). Some anomalous evidence regarding market efficiency. *Journal of financial economics*, 6(2/3), 95–101.
- Majhi, R., Panda, G., Sahoo, G., Panda, A., & Choubey, A. (2008). Prediction of S&P 500 and DJIA stock indices using particle swarm optimization technique. İçinde *2008 IEEE Congress on Evolutionary Computation (IEEE World Congress on Computational Intelligence)* (ss. 1276–1282).
- Mills, T. C. (1991). Nonlinear time series models in economics. *Journal of Economic Surveys*, 5(3), 215–242.
- Nelson, D. B. (1991). Conditional heteroskedasticity in asset returns: A new approach. *Econometrica: Journal of the Econometric Society*, 347–370.
- Oh, K. J., & Kim, K. (2002). Analyzing stock market tick data using piecewise nonlinear model. *Expert Systems with Applications*, 22(3), 249–255.
- Ou, P., & Wang, H. (2010). Financial Volatility Forecasting by Least Square Support Vector Machine Based on GARCH, EGARCH and GJR Models: Evidence from ASEAN Stock Markets. *International Journal of Economics and Finance*, 2(1), 51–64. <https://doi.org/10.5539/ijef.v2n1p51>
- Package, T., Gosso, A. A., & Training, D. (2015). Package ‘elmNN’.
- Pérez-Cruz, F., Afonso-Rodríguez, J. A., Giner, J., & others. (2003). Estimating GARCH models using support vector machines*. *Quantitative Finance*, 3(3), 163–172.
- Priestley, M. B. (1988). Non-linear and non-stationary time series analysis. *nlns*.
- Tay, F. E., & Cao, L. (2001). Application of support vector machines in financial time series forecasting. *Omega*, 29(4), 309–317. [https://doi.org/10.1016/S0305-0483\(01\)00026-3](https://doi.org/10.1016/S0305-0483(01)00026-3)
- Ture, M., & Kurt, I. (2006). Comparison of four different time series methods to forecast hepatitis A virus infection. *Expert Systems with Applications*, 31(1), 41–46.
- Wang, J.-Z., Wang, J.-J., Zhang, Z.-G., & Guo, S.-P. (2011). Forecasting stock indices with back propagation neural network. *Expert Systems with Applications*, 38(11), 14346–14355.
- Wang, Y.-F. (2003). Mining stock price using fuzzy rough set system. *Expert Systems with Applications*, 24(1), 13–23.
- Yao, J., Tan, C. L., & Poh, H.-L. (1999). Neural networks for technical analysis: a study on KLCI. *International journal of theoretical and applied finance*, 2(02), 221–241.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159–175.
- Zhong, X., & Enke, D. (2017). Forecasting daily stock market return using dimensionality reduction. *Expert Systems with Applications*, 67, 126–139. <https://doi.org/10.1016/j.eswa.2016.09.027>