

MLP/RBF Ağ Mimarileriyle Hibrit MGARCH-ANN Model Performans Karşılaştırması: Petrol Fiyat Oynaklığı

Nurcan METİN*

Kübra KARADAĞ**

M. Kenan TERZİOĞLU***

Geliş Tarihi (Received): 01.04.2020 – Kabul Tarihi (Accepted): 05.05.2020

Öz

Ticari mallar olarak ifade edilen emtia, sanayi metalleri, değerli metaller, tarımsal ürünler ve enerji ürünleri gibi birçok alt gruba ayrılmaktadır. Yüksek işlem hacimli enstrümanlar arasında olan ve birincil enerji tüketiminde ilk sırada yer alan petrolün fiyatındaki oynaklığının artmasıyla ortaya çıkan belirsizlik, tüketicilerin ve üreticilerin harcama, tasarruf ve yatırım kararlarını değiştirmesine ve potansiyel olarak kaynakların yeniden tahsis edilmesine neden olmaktadır. Yüksek frekanslı serilerde zamana göre değişen ve kümelenme eğilimi gösteren oynaklığın modellenmesinde çoğunlukla Genelleştirilmiş Otoregresif Koşullu Değişen Varyans (GARCH) tipi modellerden faydalanılmaktadır. Bununla birlikte, doğrusal yapının yanında eğrisel yapıyı da modelleyebilen Yapay Sinir Ağları (ANN), GARCH-tipi modellere iyi bir seçenek olarak ortaya çıkmaktadır. Çalışma kapsamında, literatürde henüz yaygın olarak kullanılmayan, sistem olarak tahmin edilen çok değişkenli GARCH tipi modellerden elde edilen oynaklık değerlerinin ANN’de çıktı katmanı olarak yer almasıyla elde edilen hibrit model (Tip-II) yapısı kullanılarak Eylül-1992 ve Temmuz-2019 dönemleri itibariyle petrol fiyatlarındaki oynaklık yapısı incelenmektedir. Hibrit modeller ile elde edilen tahminler karşılaştırıldığında, en iyi performans değerlerine çok değişkenli GARCH-tipi model sınıfına ait olan Dinamik Koşullu Korelasyon Modeli (DCC-MGARCH) ve Çok Katmanlı Algılayıcı Modeller (MLP) tarafından oluşturulan model yapısı ile ulaşıldığı belirlenmektedir.

Anahtar Kelimeler: Yapay sinir ağları, MGARCH model, hibrit model, ham petrol fiyat endeksi

* Prof. Dr., Trakya Üniversitesi, İ.İ.B.F. Ekonometri Bölümü Öğretim Üyesi, nurcanmetin@trakya.edu.tr,
ORCID ID: 0000-0002-8761-66033

** Arş. Gör., Trakya Üniversitesi, İ.İ.B.F. Ekonometri Bölümü Öğretim Elemanı, kubrakaradag@trakya.edu.tr,
ORCID ID: 0000-0003-4631-7102

*** Doç. Dr., Trakya Üniversitesi, İ.İ.B.F. Ekonometri Bölümü Öğretim Üyesi, Sorumlu Yazar,
kenanterzioglu@trakya.edu.tr, ORCID ID: 0000-0002-6053-830X

Hybrid MGARCH-ANN Model Performance Comparison with MLP/RBF Network Architectures: Oil Price Volatility

Abstract

Commodities are divided into many sub-groups such as industrial metals, precious metals, agricultural products and energy products. The uncertainty caused by the increase in the price volatility of oil which is in the first place in primary energy consumption and among the instruments with high transaction volume, causes consumers and producers to change their expenditure, savings and investment decisions and potentially reallocate resources. Generalized Autoregressive Conditional Variable Variance (GARCH) type models are mostly used in modeling of volatility that varies with time and tends to cluster in high frequency series. Artificial Neural Networks (ANN), which can model the curvilinear structure as well as the linear structure, is a good option for GARCH-type models. Within the scope of the paper, it is aimed to examine the oil prices volatility structure between September-1992 and July-2019 periods using hybrid model (Type-II) structures, not widely implemented in the literature yet, obtained by using the volatilities obtained from the multivariate GARCH type (MGARCH) models, estimated as a system, in the output layer in ANN. When the estimates obtained with the hybrid models are compared, the best performance value is detected with the multivariate GARCH-type model structure generated by the Dynamic Conditional Correlation Model (DCC-MGARCH) and the Multilayer Perceptron Models (MLP)

Keywords: *Artificial neural networks, MGARCH model, hybrid model, crude oil price index*

Giriş

Finans piyasalarında öngörülemez ani iniş çıkışlar olarak tanımlanan oynaklığın tahmininin yapılması yatırım kararı verme, politika oluşturma ve risk yönetimi gibi konularda karar vericiler için önemli rol oynamaktadır. Emtia piyasasında yüksek işlem hacmine sahip ve en birincil enerji tüketim kaynağı olan petrol fiyatındaki oynaklığın modellenmesi ve tahmin edilmesi, yatırım ve politika kararlarını diğer makroekonomik değişkenlerle etkileşime girerek etkilediğinden önem arz etmektedir. Altın ve petrol fiyatlarının dolar kuru cinsinden işlem görmesi sonucunda döviz kurunda oluşan değişimler emtiaların fiyat değişimi üzerinde etkili olmaktadır. Bu nedenle, piyasalara etkisi döviz kuru üzerinden gerçekleşen uluslararası ham petrol fiyat düzeyi ile en fazla işlem gören değerli madenler sınıfında yer alan altın fiyat düzeyi arasında ilişki bulunmaktadır. Krugman (1980) ve Caprio ve Clark (1981), ham petrol fiyatları ve döviz kuru arasındaki ilişkiyi ele alarak ham petrol ile döviz kuru arasında, petrol ihraç eden ülkelerde simetrik, petrol ithal eden ülkelerde ise asimetric bir ilişki olduğunu vurgulamaktadır. Amano ve Van Norden (1998), reel döviz kuru hareketlerini inceleyerek petrol fiyatlarındaki değişimle ilişkisini ortaya koymaktadır. Chaudhuri ve Daniel (1998), petrol fiyatlarının durağan olmayan hareketlerin döviz kurundaki hareketlilikten kaynaklandığını göstermektedir. Poyraz ve Didin (2008), altın fiyatlarının döviz kuru, döviz rezervi ve petrol fiyatlarından etkilendiğini belirtmektedir. Joy (2011), altın fiyatlarındaki değişimin Amerikan doları fiyatlarındaki değişimle ters ilişki içerisinde olduğunu ortaya koymaktadır.

Kuper (2002), petrol fiyat serisindeki oynaklığı GARCH modeli ile açıklamaktadır. Maghyreh (2006), ham petrol fiyat şokları ile borsa getirileri arasındaki dinamik ilişkiyi vektör otoregresif (VAR) model yaklaşımını kullanarak incelemekte ve anlamlı bir ilişkinin olmadığını ifade etmektedir. Güloğlu ve Akman (2007), döviz kurundaki oynaklık tahminlerini ARCH, GARCH ve Markov dönüşümlü ARCH (SWARCH) modelleri kullanarak incelemektedir. Cheong (2009), petrol fiyatlarındaki değişimi ARCH modeli ile ele almaktadır. Wang ve Wu (2012), enerji piyasasındaki oynaklığı GARCH ve çok değişkenli GARCH sınıfı modellerini kullanarak incelemekte ve enerji fiyat oynaklıklarında uzun hafızanın varlığını ortaya koymaktadır. Yapay sinir ağları, emtia fiyatlarının analizinde en önemli makine öğrenme modelleri arasında yer almaktadır. (Parisi vd., 2008). Sánchez Lasheras vd. (2015), emtia spot fiyat verilerini kullanarak ARIMA ve ANN modelinin öngörülen performanslarını değerlendirerek yapay sinir ağlarının üstünlüğünü vurgulamaktadır. Ramyar ve Kianfar (2017), ham petrol fiyatlarını tahmin etmek için MLP sinir ağı modeli geliştirerek MLP sinir ağının VAR modeline göre üstünlüğünü göstermektedir. Ignácio vd. (2017), petrol fiyatlarını tahmin

etmek için Levenberg-Marquardt (LM) eğitim algoritması yardımıyla MLP sinir ağı oluşturularak petrol fiyatlarının öngörüsünde ANN'nin doğruluğunu ortaya koymaktadır. Petrol fiyatlarındaki oynaklığın modellenmesinde ve tahmin edilmesinde GARCH-tipi modeller ve ANN birlikte ele alınarak hibrit model yapısı oluşturulabilmektedir. Kristjanpoller ve Minutolo (2016), ANN modeli ile GARCH model yapısını birleştirerek, petrol fiyatlarındaki dalgalanmanın önceki kurulan modellere göre %30 daha doğru tahminlenmesinin sağlandığını göstermektedir. Çam vd. (2017), petrol fiyatlarındaki oynaklığı GARCH ve ANN modelleri kapsamında ele alarak, oynaklık değerleri üzerinde en çok hangi değişkenin etkili olduğunu önem analizini kullanarak belirlemektedir. Kristjanpoller ve Hernández (2017), emtia fiyatlarının oynaklığını tahmin etmek için hibrit ANN ve GARCH model yapısı kullanarak, hibrit model kullanılmasının tahmin doğruluğunu arttırdığını ifade etmektedir. Baffour vd. (2019), emtia fiyatları serisinin modellenmesinde sadece GJR modelinin kullanılması yerine hibrit ANN-GJR modelinden faydalanılmasının hatayı %90 oranında azalttığını vurgulamaktadır.

Makale kapsamında, mümkün olan tüm etkileşimleri bir arada ele alan ve tam bilgiyle çözümler elde eden çok değişkenli yapıyla ifade edilen denklem sisteminden yararlanılarak, petrol fiyat endeksi, altın fiyat endeksi ve döviz kuru paritesi arasındaki ilişki yapısına ait ortalama-model uygun vektör otoregresif yapıyla kurgulandıktan sonra petrol fiyat endeksi oynaklık tahmin performanslarının hibrit Tip-II (MGARCH-ANN) model yapılarıyla ortaya çıkartılarak literatüre katkı sağlanması amaçlanmaktadır.

1. Ekonometrik Metodoloji

Hibrit modeller matematiksel, istatistiksel, ekonometrik veya yapay sinir ağları gibi çoklu öğrenme yöntemleri ile farklı modellerin birlikte kullanılmasını sağlayan problem çözme yöntemidir. Verilerin özellikleri hakkında tam bir bilgiye sahip olunmasının zorluğu nedeniyle hem doğrusal hem de doğrusal olmayan özellikteki problemlerin çözümüne ilişkin modelleme kabiliyetine sahip hibrit yaklaşım kullanılmaktadır (Khashei ve Bijari, 2011). Model sınırlamalarının üstesinden gelmek ve tahmin doğruluğunu artırmak için kullanılan hibrit model yapıları, problem çözümünde farklı bakış açılarının kullanılmasına imkân vermektedir. Kullanılan farklı modeller arasında çeşitliliğin olması hibrit modellerin daha başarılı sonuçlar elde etmesini sağlamaktadır (Kuncheva L. vd., 2003).

Nöronun temel unsur olduğu sinir sistemini taklit ederek öğrenme sürecine sahip yapay sinir ağları (ANN), gelecekte ortaya çıkması muhtemel durumlarda verilecek tepkilerin belirlenmesini sağlayan parametrik olmayan matematiksel modelleme yöntemidir. ANN yapısı, yapay nöron, girdiler (dış ortamdan ya da diğer hücrelerden gelen ağın öğrenmesi için

kullanılan veriler), ağırlıklar (sinaps-verilerin etkisini belirleyen değerler), toplama fonksiyonu (dentrit-hücreye gelen her bir girdiyi, işlem elemanına bağlayan ağırlık değeriyle çarparak net girdiyi hesaplayan fonksiyon), transfer fonksiyonu (aktivasyon fonksiyonu-toplama fonksiyonundan gelen girdiyi işleyerek istenilen değerler arasında sınırlandıran ve yapay sinir hücresinin çıktısını belirleyen fonksiyon) ve çıktılar (aksonlar-ara katmanlardan gelen bilgileri işleyerek dış dünyaya gönderen elemanlar) olmak üzere beş kısımdan oluşmaktadır. Girdiler, n elemanlı bir vektör olarak ($X = [X_1, X_2 \dots X_n]'$) tanımlanırken ağırlıklar ($W = [W_1, W_2 \dots W_n]$) satır vektörü ile gösterilmektedir. Toplama fonksiyonu ile net girdi ($\sum_{i=1}^n x_i w_i$) hesaplanmaktadır. Transfer fonksiyonu ile veri genellikle $[0,1]$ veya $[-1,1]$ değerleri arasında sınırlandırılmaktadır. Yapay sinir ağlarında en sık kullanılan transfer fonksiyonları arasında doğrusal fonksiyon, adım(step) fonksiyonu, sigmoid fonksiyonu ve hiperbolik tanjant fonksiyonu yer almaktadır. Tablo 1'de ANN'de sık kullanılan transfer fonksiyonları gösterilmektedir. Radyal bazlı fonksiyonlarda ise genellikle Gausyen fonksiyonu kullanılmaktadır. Çıktılar ($y_1, y_2 \dots y_n$) olmak üzere n elemanlı vektörden oluşup problemin çözümünü temsil etmektedir.

Tablo 1. ANN Sık Kullanılan Transfer Fonksiyonları


Transfer Fonksiyonu	Fonksiyonel Yapı
Doğrusal Fonksiyon ¹	$f(x) = x$
Adım Fonksiyon ²	$f(x) = \begin{cases} 1 & \text{Net girdi} > \text{eşik değeri} \\ 0 & \text{Net girdi} < \text{eşik değeri} \end{cases}$
Sigmoid Fonksiyon ³	$f(x) = 1 / (1 + e^{-x})$
Hiperbolik Tanjant Fonksiyon ⁴	$\tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x})$
Gausyen Fonksiyon ⁵	$f(x) = (1 / \sqrt{2\pi\sigma}) e^{-(x-\mu)^2 / 2\sigma^2}$

1. $(-\infty, \infty)$ aralığında değerler üretmekle birlikte türevi sabit olduğu için genellikle tercih edilmemektedir. 2. Girdinin belirli bir eşik değeri altında veya üstünde olmasına göre (0) ya da (1) değerlerini almaktadır. 3. (0,1) aralığında değerler üretmektedir. 4. (-1,1) aralığında değer üretmektedir. Sigmoid fonksiyonuna göre aralığı daha geniş, 0 merkezli ve türevi basit formda olduğundan daha avantajlı görülmektedir. 5. Gausyen fonksiyonunda çıkış değeri, girdinin seçilen ortalama değere yakınlığına bağlı olarak (1) veya (0) cinsinden değerler almaktadır.


Yapay sinir ağları, girdi-çıkı elemanları, katmanlara yerleştirilen ve birbirine bağlanan yapay nöronlar ve oluşturulan sinir sistemleri arasındaki bağlantıların ağırlıklarıyla öğrenme ve eğitim sürecine dâhil edilmektedir. Basit algılayıcı modelini sınıflandırma amacıyla kullanan Rosenblat (1958), tek gizli katman için ileri beslemeli yapay sinir ağlarını ve perceptron (algılayıcı) kavramlarını ortaya koymaktadır. Şekil 1'de yapay sinir hücresine ait temel gösterim verilmektedir. Basit algılayıcı modeller, karşılaşılan doğrusal olmayan problemlerin çözümünde yetersiz kaldığından Minsky (1969), Çok Katmanlı Algılayıcı Modellerin

(Multilayer Perceptron-MLP) doğrusal ve doğrusal olmayan yapıdaki problemlerin çözümünde kullanılabileceğini belirtmektedir.

Şekil 1: Yapay Sinir Hücresi




Şekil 2: Çok Katmanlı Yapay Sinir Ağı



ANN'lerde en çok tercih edilen modellerinden olan MLP, girdi katmanı, gizli katman(lar) ve çıkış katmanı olmak üzere en az 3 katmandan oluşmaktadır. Girdi katmanı, çözülmesi istenilen probleme ilişkin bilgilerin ANN'ye tanıtılmasını sağlamaktadır. Çıktı katmanı ağ içerisinde işlenen bilginin dışarıya iletiği katmandır. Tek katmanlı ANN'lerden farklı olarak girdi ve çıktı katmanları arasında yer alan gizli katmanın sayısı ve her bir ara katmanda kullanılacak nöron sayısı problem çözücünün tercihine göre değişmektedir. Şekil 2'de çok katmanlı yapay sinir ağı model yapısı verilmektedir. Rumelhart vd. (1986), çok katmanlı algılayıcı modellerde eğitimde kullanılan hataları geriye doğru (çıkıştan girişe doğru) azaltmaya çalışan ve öğrenen hata yayma modelini (backpropagation-geri) ortaya koymaktadır. Öğrenme algoritmaları içinde en çok geriye yayılım algoritması tercih edilmektedir. MLP ağları danışmalı öğrenme stratejileri kapsamında eğitim sırasında hem girdiler hem de girdilere karşılık ağın üretmesi gereken çıktılar ağı tanıtılmaktadır. Girdi-gizli ve gizli-çıkı katmanı ve ağırlıklar ilk önce rastgele seçilmektedir. Giriş sinyalleri, ileri yönde katmandan katmana yayılmaktadır. Eğitim sırasında ağın ürettiği çıktılar ile beklenen (üretmesi gereken) çıktılar arasındaki fark (hata) ağın ağırlıklarına dağıtılmakta ve zaman içinde bu farkın en aza indirgenmesi amaçlanmaktadır. Çıktının, istenen nöron cevabından farklı olması durumunda hatalar ileri besleme aktarım işlevinin türeviyle aynı bağlantılar aracılığı ile geriye doğru yayılmakta ve ağırlıklarda değiştirilmektedir. Bilgi akışı, ileri beslemeli modellerde olduğu gibi ileri yönde sağlanırken geri beslemeli ağlarda öğrenme işlemi çift yönlü hafıza işleme sürecine dayanmaktadır (Elmas, 2018). MLP ağlarında örneklerin anakütleyi temsil edebilmesi, değişken seçimi, katman sayısı ve kullanılacak nöron sayısı, başlangıç değerleri, öğrenme katsayıları, durdurma kriteri gibi faktörler ağların başarısını etkilediğinden bu faktörlerin dikkatlice değerlendirilmesi ve problemin çözümü için en uygun yaklaşımın kullanılması gerekmektedir.


Moody ve Darken (1989), çok katmanlı algılayıcılara alternatif olarak fonksiyon yaklaşımı teorisi ile ilişkili olan Radyal Tabanlı Fonksiyonları (RBF) önermektedir. RBF, çok değişkenli modelleme ve yakınsamalarda, doğrusal/doğrusal olmayan ve herhangi bir basit/çok katmanlı yapay sinir ağlarında kullanılabilir. Girdi katmanını gizli katmana bağlayan ağırlık değerlerini kullanmak yerine veri kümesinde girdinin merkeze uzaklığına (genellikle öklid uzaklığı) göre ağırlık değeri belirlenmektedir. MLP ağlarında olduğu gibi RBF ağlarında da kullanılacak gizli katman ve nöron sayısının seçimi önemli olmaktadır. Az sayıda katman kullanıldığında ilişkilerde oluşacak radyal tabanlı fonksiyonlar girdi ile çıktı arasındaki ilişkiyi yakalamakta yetersiz kalabilmektedir. Girdi, işlenmeden doğrudan gizli katman nöronlarına iletdikten sonra RBF'ler aracılığıyla işlenmekte ve ilgili ağırlık değerleri ile çarpılarak çıktıların ağırlıklı toplamlarına eşitlenen çıktı katmanına iletilmektedir. Radyal temelli fonksiyon ağlarında girdi katmanı doğrusal olmayan niteliğe çıktı katmanı ise doğrusal niteliğe sahip olmaktadır. Öğrenme aşamasında parametre sayısında azalma gerçekleşirken öğrenme hızlanmakta, giriş sayısı arttıkça yüksek boyutlu RBF ağ yapılarına ihtiyaç duyulmaktadır. Şekil 3 ve Şekil 4'de radyal bazlı fonksiyon sinir ağı ve geri yayılım model yapısı verilmektedir.

Şekil 3: Radyal Bazlı Fonksiyon Sinir Ağı



Kaynak: Yılmaz, 2012

Şekil 4: Geri Yayılım Yapay Sinir Ağı



Kaynak: Yılmaz, 2012

Zaman boyunca ortaya çıkan ve bazen ortalama değere yönelme eğiliminde bazen uç değerlere neden olan getirilerdeki değişimin standart sapması oynaklık olarak adlandırılmaktadır. Belirli bir t zamanında gözlemlenen getiriye ait (r_t), koşullu beklenen değer (μ_t), koşullu hata (ε_t), koşullu varyans (h_t), sıfır ortalama ve birim varyansa sahip olan bağımsız-aynı normal dağılımlı stokastik süreç (z_t) iken, \mathcal{F}_{t-1} bilgi matrisi altında, $\varepsilon_t = \sqrt{h_t}z_t \sim N(0, h_t)$ ifade edilmektedir. $i=1, \dots, q$ için $\omega \geq 0$, $p \geq 0$, $q > 0$ ve $\alpha_i \geq 0$ ile $\beta_i \geq 0$ altında GARCH(p,q) modeli $h_t = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j h_{t-j}$ şeklinde elde edilmektedir (Orskaug,2009). Oynaklıklar zaman içinde kümelenme eğiliminde olduğundan, MGARCH yaklaşımı kullanılarak çeşitli piyasalar ve varlıklar arasındaki kovaryansların zaman içindeki değişimlerinin belirlenmesi hem daha gerçekçi sonuçlara ulaşılmasını hem de risk yönetiminde daha iyi kararlar alınmasına neden olarak etkinlik kazanımı sağlamaktadır

(Terzioğlu,2018). \mathcal{F}_{t-1}' e göre H_t ölçülebilir ise çok değişkenli GARCH modeli $\varepsilon_t|\mathcal{F}_{t-1} \sim N(0, H_t)$ olarak tanımlanabilmektedir. Makale kapsamında, VEC-GARCH modelin sınırlandırıcı bir versiyonu olarak tanımlanan Baba-Engle-Kraft-Kroner (BEKK) modeli ve GARCH modellerinin doğrusal olmayan kombinasyonlarından olan dinamik koşullu korelasyon (DCC) modeli kullanılmaktadır. A_{kj} , B_{kj} ve C , $N \times N$ parametre matrisi ve C alt üçgen olmak üzere, K toplama limit sürecin genellenabilirliğini göstermek üzere, BEKK(p,q,K) modeli

$$H_t = CC' + \sum_{j=1}^q \sum_{k=1}^K A'_{kj} \varepsilon_{t-j} \varepsilon'_{t-j} A_{kj} + \sum_{j=1}^p \sum_{k=1}^K B'_{kj} H_{t-j} B_{kj} \quad (1)$$

şeklinde gösterilmektedir. Sabit terimin iki üçgen matris çarpımına ayrıştırılması varyans matrisinin (H_t) pozitif tanımlılığını garantilemektir (Silvennoinen ve Terasvirta, 2007). Koşullu varyans ve korelasyonları kullanarak koşullu kovaryansların doğrudan modellenmesi görece olarak yeni bir yaklaşım olarak ortaya çıkmaktadır. Zamana bağlı korelasyonlar genellikle getirilerin çapraz çarpımı ve karelerinde doğrusal olan MGARCH modelleri ile hesaplanmaktadır. $\varepsilon_t = D_t^{-1} r_t$ ve $D_t = \text{diag}\{\sqrt{h_{i,t}}\}$ olmak üzere, $R = E_{t-1}(\varepsilon_t \varepsilon_t') = D_t^{-1} H_t D_t^{-1}$ koşullu korelasyonları içeren bir korelasyon matrisini göstermek üzere sabit koşullu korelasyon tahmin edicisinin geliştirilmiş hali olan DCC modeli

$$H_t = D_t R_t D_t \quad (2)$$

şeklinde gösterilmektedir. R 'nin parametrisasyonu koşullu varyansların bütünlük içinde olmasının dışında H ile aynı gerekliliklere sahiptir (Engle, 2001).

GARCH-tipi modeller ve ANN kullanılarak iki farklı şekilde hibrit modeli oluşturulmaktadır. İlk yaklaşımda (Tip-I) GARCH tipi modeller ile elde edilen oynaklık değerleri ANN algoritmasına açıklayıcı değişken olarak alınırken, diğer bir yaklaşım da GARCH tipi modeller ile elde edilen oynaklık değerleri ANN'de çıktı katmanına eklenerek oluşturulmaktadır. GARCH-tipi modeller ile tahminlenen oynaklık değerlerinden daha iyi sonuçlar elde edilmesi amaçlanmaktadır (Lu vd., 2016). X_t açıklayıcı değişkenlerini, W_t girdi katmanı ile gizli katman arasındaki ağırlıklar matrisini, F_1 girdi katmanı ile gizli katman arasındaki toplam fonksiyonunu, V_t gizli katman ile çıktı katman arasındaki ağırlık matrisini, F_2 gizli katman ile çıktı katmanı arasındaki aktivasyon fonksiyonunu ve h_t^* yapay sinir ağırları çıktı verisini tanımlamak üzere, Tip-II model yapısı

$$h_t^* = F_2[(V_t^T F_1(W_t X_t))] \quad (3)$$

şeklinde gösterilmektedir (Yu vd., 2007).


2. Petrol Fiyat Endeksi Oynaklık Tahmininde Model Performans Karşılaştırması

Makale kapsamında, Uluslararası Para Fonu (IMF) veri tabanından Eylül-1992 ve Temmuz-2019 dönemleri arasında, 2016 yılı baz alınarak, Brent, West Texas Intermediate ve Dubai Fateh'e ait üç spot fiyatın ortalamasından elde edilen ham petrol fiyat endeksi, altın fiyat endeksi (Usd/Ons) ve Euro/Dolar parite verileri elde edilerek, GARCH-tipi modeller ve Yapay Sinir Ağları algoritması birleştirilerek oluşturulan hibrit modellerle petrol fiyatlarındaki oynaklığın ortaya çıkartılması amaçlanmaktadır. Petrol fiyat endeksi, altın fiyat endeksi ve parite değişkenlerinin durağanlık ve mevsimsel etkileri incelenmiş ve logaritmik birinci sıra farkları alınarak 100 ile çarpılması sonucunda yüzde değişimler olarak ifade edilen büyüme ölçüleri elde edilmektedir. Logaritmik birinci sıra fark serilerinin zamana göre eğilimine ilişkin grafiksel gösterim Grafik 1.'de ve model yapısında kullanılan ilgili değişkenlerin tanımlayıcı istatistikleri Tablo 2.'de verilmektedir. Model yapısında son tahmin hata (FPE) kriteri için gecikme uzunluğu 3 olarak hesaplandığından ilgili değişkenlerin arasındaki ilişkinin modellenmesi için VAR(3) süreci oluşturulmaktadır.

Tablo 2: Tanımlayıcı İstatistikler.

	Petrol	Altın	Euro/USD		Petrol	Altın	Euro/USD
Ortalama	0,332	0,455	-0,083	Std.Sapma	8,138	3,551	2,797
Maksimum	20,144	16,196	9,626	Çarpıklık	-0,822	0,330	-0,262
Minimum	-31,724	-12,481	-10,226	Basıklık	1,499	1,625	1,139

Grafik 1: Logaritmik Birinci Sıra Fark Serilerinin Zamana Göre Eğilimine İlişkin Grafiksel Gösterim



Yukarıdan aşağıya doğru sıralanmaktadır: 1. Petrol fiyat endeksi, 2. Altın fiyat endeksi ve 3.Euro/Dolar Paritesi

VAR(3) modeli kapsamında hatalarda ve/veya hata karelerinde otokorelasyon olduğunun tespit edilmesi, MGARCH modellerinin kullanımına yöneltmektedir. Kurulan model yapısında çok değişkenli ARCH etkisi önsel testi yapılarak ARCH etkisinin yokluğunun tam anlamıyla ret edildiği belirlenmektedir. PFE_t petrol fiyat endeksini, AFE_t altın fiyat

endeksini, EUP_t Euro/Dolar paritesini ve h_{PFE_t} ise petrol fiyat oynaklığını göstermek üzere MGARCH model yapısı

$$PFE_t = a_1 + \sum_{i=1}^p a_{2i} PFE_{t-i} + \sum_{i=1}^p a_{3i} AFE_{t-i} + \sum_{i=1}^p a_{4i} EUP_{t-i} + \varepsilon_{PFE_t} \quad (4)$$

$$AFE_t = b_1 + \sum_{i=1}^p b_{2i} PFE_{t-i} + \sum_{i=1}^p b_{3i} AFE_{t-i} + \sum_{i=1}^p b_{4i} EUP_{t-i} + \varepsilon_{AFE_t} \quad (5)$$

$$EUP_t = c_1 + \sum_{i=1}^p c_{2i} PFE_{t-i} + \sum_{i=1}^p c_{3i} AFE_{t-i} + \sum_{i=1}^p c_{4i} EUP_{t-i} + \varepsilon_{EUP_t} \quad (6)$$

$$\varepsilon_{PFE_t} = \sqrt{h_{PFE_t}} * z_t \quad (7)$$

şeklinde oluşturulmaktadır. Makale kapsamında, ilgilenilen değişkenlere ait oynaklıklar BEKK ve DCC yapıları kapsamında kısıtlanmaktadır. BEKK model yapısında, K toplam limitinin değerinin artması birkaç parametrisasyon modelinin aynı gösterimini oluşturmakta ve tanımlama problemlerine neden olduğundan $p=q=K=1$ kabul edilmektedir. GARCH (1,1) modeline ait oynaklık değerleri elde edildikten sonra model parametreleri incelenerek gerekli şartların sağlandığı da görüldükten sonra VAR-BEKK-MGARCH ve VAR-DCC-MGARCH model yapıları kullanılarak petrol fiyat endeksine ilişkin oynaklık değerleri elde edilmektedir. GARCH-tipi modeller kullanılarak elde edilen petrol fiyat oynaklık değerlerini ANN’de çıktı değişkeni olarak oluşturulan Tip-II model yapısına sahip hibrit model kullanılmaktadır. Bu kapsamda, petrol fiyat endeksine, Euro/Usd paritesine ve altın fiyat endeksine ilişkin getiri değerleri hibrit model yapısına girdi olarak tanımlanırken, GARCH-tipi modeller ile elde edilen oynaklık değerleri modele hedef değişkeni olarak tanımlanmaktadır.

Tablo 3: ANN modellerinde kullanılan parametre değerleri

MLP ağı için kullanılan parametreler		RBF ağı için kullanılan parametreler	
Girdi değişken sayısı	3	Girdi değişken sayısı	3
Gizli katman nöron sayısı	2-18	Gizli katman nöron sayısı.	2-18
Aktivasyon fonksiyonu	Hiperbolik tanjant (Tanh)	Aktivasyon fonksiyonu	Gausyen
Kullanılan algoritma	Backpropogation		
Rastsal eğitim çevrim (epoch) sayısı	0,0000001		
Öğrenme parametresi	0,01		

Yapay sinir ağlarının eğitilmesi ve tahmin edilmesi amacıyla farklı mimari yapılarda 15 adet çok katmanlı algılayıcı ve 15 adet radyal temelli fonksiyonlardan oluşan yapay sinir ağı modeli oluşturularak, hem MLP hem RBF için 15 adet modelin 5 adeti GARCH(1,1), 5 adeti BEKK-MGARCH ve son 5 adeti de DCC-MGARCH modelinden elde edilen oynaklık verileri incelenmektedir. Her değişken için 426 adet gözlemin %70’i eğitim, %15’i validasyon, %15’i ise test amacıyla alt kümelerine ayrıştırılmaktadır. Tablo 3.’de ANN modelinde MLP ve RBF ağı için kullanılan parametrelere yer verilmektedir. MLP modelleri, ağ yapısının tekrardan

çalıştırılmasında rastgele gözlemlerden yeniden iterasyona başladığı için elde edilen sonuçlarda farklılaşma meydana gelmektedir. Bu nedenle, MLP performansında ortalama değeri yakalamak için ağılar 100 defa eğitilerek en iyi 5 çalışmanın performans değerleri hesaplanmaktadır.

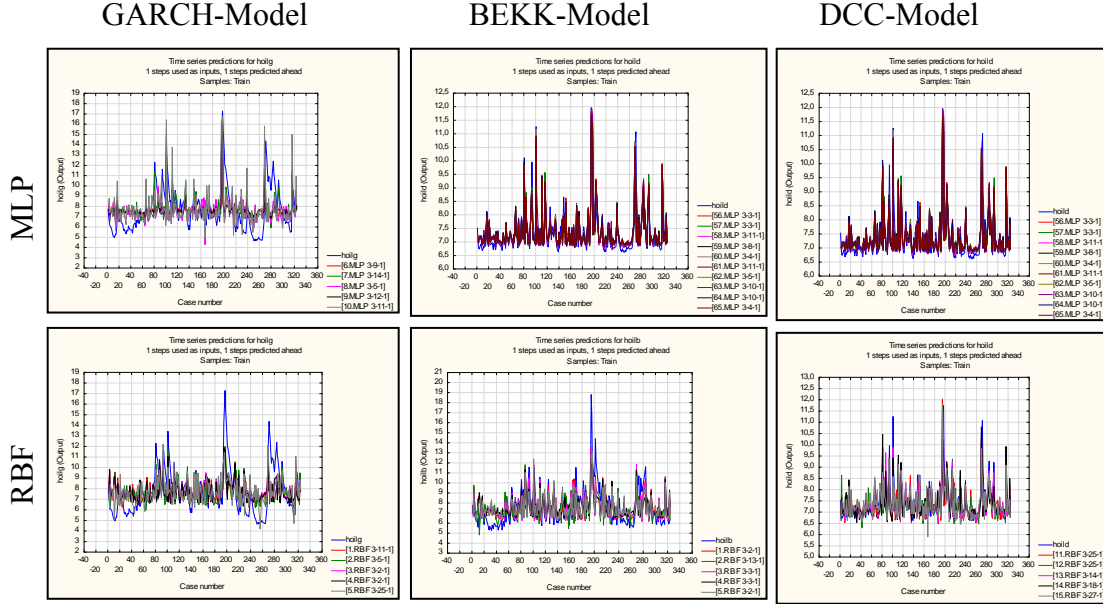
Tablo 4: Model Tahmin Sonuçları

		Eğitim Perform.	Test Perform.	Geçerlilik Perform.	MSE
MLP 3-11-1	BEKK	0,82887	0,74613	0,80121	1,11664
MLP 3-8-1	BEKK	0,82622	0,74788	0,80192	1,13367
MLP 3-4-1	BEKK	0,82081	0,75195	0,80878	1,16898
MLP 3-5-1	BEKK	0,82380	0,74630	0,80293	1,14357
MLP 3-4-1	BEKK	0,82548	0,74395	0,80215	1,13099
MLP 3-3-1	DCC	0,89609	0,86375	0,91594	0,16008
MLP 3-11-1	DCC	0,89246	0,84370	0,90745	0,16538
MLP 3-8-1	DCC	0,88853	0,85068	0,90662	0,17149
MLP 3-5-1	DCC	0,88714	0,84518	0,90709	0,17378
MLP 3-10-1	DCC	0,88895	0,85310	0,91142	0,17052
MLP 3-9-1	GARCH	0,46425	0,59077	0,68741	3,82715
MLP 3-14-1	GARCH	0,55893	0,55190	0,72297	3,35304
MLP 3-5-1	GARCH	0,47113	0,65634	0,68509	3,81750
MLP 3-12-1	GARCH	0,51042	0,56729	0,68688	3,60567
MLP 3-11-1	GARCH	0,49241	0,56891	0,68203	4,16549
RBF 3-2-1	BEKK	0,67951	0,76406	0,79829	1,91071
RBF 3-13-1	BEKK	0,64950	0,67073	0,80699	2,05379
RBF 3-3-1	BEKK	0,68556	0,78331	0,84191	1,88127
RBF 3-3-1	BEKK	0,58451	0,77473	0,80379	2,33684
RBF 3-2-1	BEKK	0,61696	0,71328	0,81268	2,19843
RBF 3-15-1	DCC	0,74563	0,69194	0,89248	0,36073
RBF 3-15-1	DCC	0,73488	0,78820	0,89783	0,37366
RBF 3-14-1	DCC	0,82992	0,78691	0,88435	0,25285
RBF 3-18-1	DCC	0,78745	0,87738	0,89822	0,30876
RBF 3-17-1	DCC	0,77050	0,67372	0,88810	0,33016
RBF 3-11-1	GARCH	0,44000	0,65999	0,68310	3,92572
RBF 3-5-1	GARCH	0,46835	0,53198	0,67105	3,80150
RBF 3-2-1	GARCH	0,42762	0,51647	0,66844	3,97931
RBF 3-2-1	GARCH	0,44369	0,47219	0,68215	3,90986
RBF 3-12-1	GARCH	0,53533	0,33343	0,67316	3,47306

MLP modellerinin aksine, RBF modellerinde ağ yapısı eğitime rastgele gözlemden başlamadığından eğitim sonuçlarında aynı değerler elde edilmekte ortalama performans hesaplanması için yeniden eğitime ihtiyaç duyulmamaktadır. Tablo 4.'de çok katmanlı ağ modelleri için model tahmin sonuçları verilmektedir. ANN'nin başarı performansı sıralamasında ağ algoritmasının test kümesini ne kadar hatayla öğrendiği, geçerlilik

kümesindeki başarısı, test kümesindeki başarısı ve her bir model yapısı için hata kare ortalaması (MSE) dikkate alındığında, en iyi tahminin DCC-MGARCH ve 3-3-1 mimari yapıya sahip çok katmanlı algılayıcı ağ tarafından 0.91 performans değeri ile üretildiği sonucuna ulaşılmaktadır.

Grafik 2. Çok Katmanlı Ağ Modelleri İçin Gruplandırılmış Tahmin Sonuçları



Grafik 2.'de çok katmanlı ağ modelleri için elde edilmiş tahmin sonuçları modellere göre gruplanarak verilmektedir. Tek değişkenli GARCH model yapısı ile oluşturulan hibrit modeller hedef oynaklık değerlerine çok yakın sonuçlar göstermemesine karşın en iyi performansa sahip DCC-MGARCH ve MLP ağlarından elde edilen hibrit model yapısına ait tahmin serisinde oynaklık değerleri büyük ölçüde hedef serisine benzer eğilimler göstermekte ve yakın şekilde takip etmektedir.

Sonuçlar

Temel enerji kaynakları içerisinde ihtiyacın büyük kısmını karşılayan petrolün ekonomiler üzerindeki kritik rolü ele alındığında, petrol fiyat oynaklıklarının ekonomiler üzerinde derin etkilere sebep olduğu söylenebilmektedir. Makale kapsamında, petrol fiyat oynaklığını doğru bir şekilde tahminlemek için en uygun modelin seçimi amaçlanmıştır. GARCH-tipi modeller ve ANN kullanılarak iki farklı şekilde hibrit modeli oluşturulmaktadır. GARCH-tipi modeller ile elde edilen oynaklık değerlerinin ANN algoritmasına açıklayıcı değişken olarak alınmasıyla oluşturulan Tip-I hibrit modeller üstüne yoğunlaştırıldığı

gözlemlenmiştir. Ek olarak, Tip-I modeller kapsamında yapılan çalışmalarda GARCH-tipi model yapısını konu alan çalışmalar bulunmakla birlikte; MGARCH-tipi model yapısını konu alan çok az çalışma bulunmaktadır. Tip-II hibrit model yapısında ise GARCH tipi modeller ile elde edilen oynaklık değerleri ANN’de çıktı katmanına eklenerek oluşturulmaktadır. Ek olarak, Tip-II modeller kapsamında yapılan çalışmalarda GARCH-tipi ve/veya MGARCH-tipi model yapısını konu alan neredeyse yok denecek kadar az çalışma bulunmaktadır. Çalışma kapsamında, Eylül-1992 ve Temmuz-2019 dönemine ait veriler kullanılarak petrol fiyatlarındaki oynaklık tahmininin performansının belirlenmesi için MGARCH-tipi model yapısı ve ANN algoritması kullanılarak elde edilen Tip-II hibrit modeller incelenmiştir. DCC-MGARCH ve MLP ağlarından elde edilen hibrit model yapısı hedef değerleri için en iyi tahmin sonuçlarını verdiğini gözlemlendiğinden, finansal varlık oynaklıklarının zaman içinde birlikte hareket etmesinden dolayı çok değişkenli modellerin tek değişkenli modellerden daha iyi performans gösterdiği ve doğrusal yapıda olmayan problemlerin çözümünde MLP ağlarının daha iyi sonuçlar verdiği sonucuna ulaşılmıştır.

Kaynakça

Amano, R. A. & van Norden, S. (1998). Oil prices and the rise and fall of the us real exchange rate. *Journal of International Money and Finance*, 17, 299-316.

Baffour, A. A., Feng, J., & Taylor, E. K. (2019). A hybrid artificial neural network-GJR modeling approach to forecasting currency exchange rate volatility. *Neurocomputing*, 365, 285-301.

Block, H. D. (1962). The perceptron: A model for brain functioning. *Reviews of Modern Physics*, 34(1), 123.

Caprio, J. & Clark, P.B. (1981). Oil price shocks in a portfolio-balance model. *International Finance Discussion Papers*, 181, 1-24.

Chatterjee, S., Sarkar, S., Hore, S., Dey, N., Ashour, A. S., & Balas, V. E. (2017). Particle swarm optimization trained neural network for structural failure prediction of multistoried RC buildings. *Neural Computing and Applications*, 28(8), 2005-2016.

Chaudhuri, K. & Daniel, B. C. (1998). Long-run equilibrium real exchange rates and oil prices. *Economic Letters*, 56, 231-238.

Cheong, C. W. (2009). Modeling and forecasting crude oil markets using ARCH-type models. *Energy policy*, 37(6), 2346-2355.

Çam, S., Balli, E., & Sigeze, Ç. (2017). Petrol Fiyatlarındaki Oynaklığın ARCH/GARCH Modelleri ve Yapay Sinir Ağları Algoritması İle Tahmini. *Uluslararası Yönetim İktisat ve İşletme Dergisi*, 13(5), 588-597.

Elmas, Ç. (2018). *Yapay Zeka Uygulamaları*, Seçkin Yayıncılık, Ankara

Engle, R.F. (2001). Dynamic conditional correlation: A simple class of multivariate GARCH models. *Journal of Business & Economic Statistics*, 20(3), 339-350.

Fang, L., Chen, B., Yu, H., & Qian, Y. (2018). The importance of global economic policy uncertainty in predicting gold futures market volatility: A GARCH-MIDAS approach. *Journal of Futures Markets*, 38(3), 413-422.

Güloğlu, B., & Akman, A. (2007). Türkiye’de döviz kuru oynaklığının SWARCH yöntemi ile analizi. *Finans Politik & Ekonomik Yorumlar*, 44(512), 43-51.

Ignácio, L. V. R., Ribeiro, L. G. A., da Veiga, C. P., & Bittencourt, J. T. (2017). The use of artificial intelligence for forecasting oil prices. *Espacios*, 38, 1-27.

Joy, M., 2011, Gold and the US Dollar: Hedge or Haven? *Finance Research Letters*, Vol. 8, Issue. 3, pp. 120-131.

Kaftan, İ. (2010). *Batı Türkiye Gravite ve Deprem Katalog Verilerinin Yapay Sinir Ağları ile Değerlendirilmesi*. Doktora Tezi, Dokuz Eylül Üniversitesi, Fen Bilimleri Enstitüsü, İzmir.

Khashei, M., & Bijari, M. (2011). A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. *Applied Soft Computing*, 11(2), 2664-2675.

Kristjanpoller, W., & Minutolo, M. C. (2016). Forecasting volatility of oil price using an artificial neural network-GARCH model. *Expert Systems with Applications*, 65, 233-241.

Kristjanpoller, W., & Hernández, E. (2017). Volatility of main metals forecasted by a hybrid ANN-GARCH model with regressors. *Expert Systems with Applications*, 84, 290-300.

Krugman, P. (1980). Oil and the dollar. *National Bureau of Economic Research Working Paper Series*, 554, 0-18.

Kuncheva, L. I., & Whitaker, C. J. (2003). Measures of diversity in classifier ensembles and their relationship with the ensemble accuracy. *Machine learning*, 51(2), 181-207.

Kuper, G. H. (2002). Measuring oil price volatility. *Available at SSRN 316480*.

Lardic, S., & Mignon, V. (2008). Oil prices and economic activity: An asymmetric cointegration approach. *Energy Economics*, 30(3), 847-855.

Lasheras, F. S., de Cos Juez, F. J., Sánchez, A. S., Krzemień, A., & Fernández, P. R. (2015). Forecasting the COMEX copper spot price by means of neural networks and ARIMA models. *Resources Policy*, 45, 37-43.

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.

Maghyereh, A. (2006). Oil price shocks and emerging stock markets: A generalized VAR approach. In *Global stock markets and portfolio management* (pp. 55-68). Palgrave Macmillan, London.

McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.

Minsky, M. L., Papert, S. A., & Perceptrons, F. (1969). The MIT Press: Cambridge. Mass.(Rev. Edition, 1988).

Moody, J., & Darken, C. J. (1989). Fast learning in networks of locally-tuned processing units. *Neural computation*, 1(2), 281-294.

Orskaug, E. (2009). Multivariate DCC-GARCH model -with various error distributions. Norwegian Computing Center.

Parisi, A., Parisi, F., & Díaz, D. (2008). Forecasting gold price changes: Rolling and recursive neural network models. *Journal of Multinational financial management*, 18(5), 477-487.

Poyraz, E., & Didin, A. G. S. (2008). Altın Fiyatlarındaki Değişimin Döviz Kuru, Döviz Rezervi Ve Petrol Fiyatlarından Etkilenme Derecelerinin Çoklu Faktör Modeli İle Değerlendirilmesi. *Süleyman Demirel Üniversitesi İktisadi Ve İdari Bilimler Fakültesi Dergisi*, 13(2), 93-104.

Ramyar, S., & Kianfar, F. (2019). Forecasting crude oil prices: A comparison between artificial neural networks and vector autoregressive models. *Computational Economics*, 53(2), 743-761.

Rezaeianzadeh, M., Tabari, H., Yazdi, A. A., Isik, S., & Kalin, L. (2014). Flood flow forecasting using ANN, ANFIS and regression models. *Neural Computing and Applications*, 25(1), 25-37.

Rosenblatt, F. (1962). *Principles of neurodynamics. perceptrons and the theory of brain mechanisms* (No. VG-1196-G-8). Cornell Aeronautical Lab Inc Buffalo NY.

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088), 533-536.

Silvennoinen, A., & Teräsvirta, T. (2007). Multivariate GARCH models. *Working Paper Series In Economics and Finance*, 669.

Terzioğlu, M. K. (2018). Effects of Inflation Uncertainty on Economic Policies: Inflation-Targeting Regime. *Management From An Emerging Market Perspective*, 235.

Wang, Y., & Wu, C. (2012). Forecasting energy market volatility using GARCH models: Can multivariate models beat univariate models?. *Energy Economics*, 34(6), 2167-2181.

Yılmaz M. (2012), Jeodezik Nokta Hız Kestiriminde Yapay Sinir Ağlarının Kullanılabilirliği, Doktora Tezi, Afyon Kocatepe Üniversitesi, Fen Bilimleri Enstitüsü

Yu, L., Wang, S., & Lai, K. K. (2007). *Foreign-exchange-rate forecasting with artificial neural networks*. Springer Science & Business Media.