

## DOĞAL GAZ FİYATININ ELMAN SİNİR AĞLARI VE YUSUFÇUK OPTİMİZASYON ALGORİTMASINA DAYALI HİBRİT MODEL İLE TAHMİNİ

Seçkin KARASU\*1

<sup>1</sup>Zonguldak Bülent Ecevit University, Faculty of Engineering, Department of Electrical and Electronics Engineering, 67100, Zonguldak, Türkiye

**Özet:** Dünya nüfusunun artışı ile çeşitli fosil ve yenilenebilir enerji kaynaklarının kullanımı giderek artmaktadır. Doğal gaz, fosil enerji kaynakları arasında yer alan kömür ve petrole karşılaştırıldığında, daha düşük karbondioksit emisyonu, yüksek verimlilik, kolay erişim ve düşük depolama maliyeti gibi özellikleri nedeniyle bireysel ve kurumsal düzeyde kullanım alanı bulmuştur. Doğal gaz fiyatı ekonomik açıdan önemli olduğu kadar stratejik öneme de sahiptir. Özellikle doğal gaz fiyatının gelecekte alacağı değerin tahmini, enerji üreticilerine ve tüketicilerine, yatırımcılara ve hükümetlere stratejik kararlar alırken yol gösterici olmaktadır. Bu çalışmada, Elman Sinir Ağları (ENN) ve Yusufçuk Optimizasyon Algoritması (DOA) yaklaşımları kullanılarak bir adım sonraki doğal gaz kapanış fiyatının tahmini yapılmıştır. Çalışma 01,06,2009-31,05,2024 tarihleri arasında 3986 adet kapanış fiyatı içeren veri seti kullanılarak yapılmıştır. Bir adım sonraki kapanış fiyatının tahmini için yapay zekâ yaklaşımlarından ENN yöntemi kullanılmıştır. Geri beslemeli sinir ağları arasında yer alan ENN, geçmiş verileri dikkate alarak gelecekteki değerleri tahmin etme yeteneğine sahiptir ve özellikle zaman serisi tahmininde kullanılmaktadır. Model eğitim aşamasında yusufçukların avlanma ve göç etme davranışlarından ilham alınarak geliştirilmiş bir sezgisel optimizasyon algoritması olan DOA yöntemiyle ENN'nin ağırlık ve bias değerleri bulunmuştur. Modelin değerlendirilme aşamasında veri setinin eğitim, doğrulama ve test setlerine bölünmesiyle modelin genelleme kapasitesi daha güvenilir bir şekilde ölçülmektedir. Model başarımı, çeşitli istatistiksel hata kriterleri kullanılarak değerlendirilmiş ve elde edilen sonuçlar tatminkâr bulunmuştur. Yapay zekâ yaklaşımlarının kullanımı, enerji piyasaları gibi dinamik ve karmaşık sistemlerde tahmin doğruluğunu artırmak için kritik önem taşımaktadır. ENN ve DOA'nın birleşimi, bu tür problemler için güçlü ve esnek bir çözüm sunmaktadır. Bu çalışma, doğal gaz fiyatlarının tahmininde yapay zekâ yöntemlerinin etkinliğini göstermekte ve bu yaklaşımların pratik uygulamalarda kullanılabilirliğini ortaya koymaktadır.

**Anahtar kelimeler:** Doğal gaz tahmini, Elman sinir ağları, Yusufçuk optimizasyon algoritması, Zaman serisi, Tahmin


### Prediction of Natural Gas Price with Hybrid Model Based on Elman Neural Networks and Dragonfly Optimization Algorithm

**Abstract:** With the increasing in the world population, the use of various fossil and renewable energy resources is increasing. Compared to coal and oil, which are among the fossil energy sources, natural gas has found use at individual and institutional levels due to its features such as lower carbon dioxide emissions, high efficiency, easy access and low storage costs. The price of natural gas is not only economically important but also strategically important. In particular, the prediction of the future value of natural gas prices provides guidance for energy producers, consumers, investors and governments when making strategic decisions. In this study, the one step ahead natural gas close price is predicted by using Elman Neural Networks (ENN) and Dragonfly Optimization Algorithm (DOA) approaches. The analysis utilized a dataset spanning from June 01, 2009, to May 31, 2024, encompassing 3986 close prices. ENN, one of the artificial intelligence approaches, is used to predict the next closing price. ENN, which is among the feedback neural networks, has the ability to predict future values by taking into account past data and is especially used in time series forecasting. During the model training phase, the weight and bias values of the ENN are found with the DOA method, which is a heuristic optimization algorithm developed inspired by the hunting and migration behavior of dragon flies. In the evaluations of the model, the generalization capacity of the model is measured more reliably by dividing the data set into training, validation and test sets. Model performance is evaluated using various statistical error criteria and the results are found to be satisfactory. The use of artificial intelligence approaches is critical to increase forecast accuracy in dynamic and complex systems such as energy markets. The combination of ENN and DOA provides a powerful and flexible solution for such problems. This study demonstrates the effectiveness of artificial intelligence methods in predicting natural gas prices and reveals the usability of these approaches in practical applications.

**Keywords:** Natural gas prediction, Elman neural networks, Dragonfly optimization algorithm, Time series, Forecasting

\*Sorumlu yazar (Corresponding author): Zonguldak Bülent Ecevit University, Faculty of Engineering, Department of Electrical and Electronics Engineering, 67100, Zonguldak, Türkiye

E mail: seckin.karasu@beun.edu.tr (S. KARASU)

Seçkin KARASU  <https://orcid.org/0000-0001-5277-5252>

Gönderi: 18 Haziran 2024

Kabul: 25 Kasım 2024

Yayınlanma: 15 Ocak 2025

Received: June 18, 2024

Accepted: November 25, 2024

Published: January 15, 2025

Cite as: Karasu S. 2025. Prediction of natural gas price with hybrid model based on elman neural networks and dragonfly optimization algorithm. BSJ Eng Sci, 8(1): 102-114.



## 1. Giriş

Doğal gaz, modern dünyanın enerji ihtiyaçlarını karşılayan temel bir kaynaktır. Endüstriyel üretimden evlerimizin ısıtılmasına kadar geniş bir yelpazede hayati bir rol üstlenmektedir (Afgan vd., 2007). Aynı zamanda elektrik üretimi (Kong vd., 2023), ulaşım (Khan vd., 2015) ve kimyasal sanayi (Szklo vd., 2004) gibi kritik sektörlerde kullanılarak yaşamımızın her yönünü etkilemektedir. Bu çok yönlü kaynağın öne çıkan avantajlarından biri, yakıldığında daha az kirletici salınımı sağlayan fosil yakıtlar içerisinde nispeten temiz bir enerji olmasıdır (Rizvi vd., 2022). Doğal gazın bu çevre dostu yanma özelliği, çevresel sürdürülebilirlik hedeflerine katkıda bulunmasını sağlamaktadır. Bunun yanı sıra, enerji güvenliği ve uluslararası ilişkiler açısından da büyük bir stratejik öneme sahiptir. Enerji sektöründeki değişen dinamikler ve çevre bilincinin artmasıyla, doğal gazın rolü giderek daha fazla önem kazanmaktadır (Gillissen vd., 2019). Ekonomik büyüme ve gelişim için gerekli enerji arzının sağlanmasında, doğal gazın esnek ve temiz özellikleri ön plana çıkmaktadır. Bu durum, enerji piyasalarında tedarik güvenliğini artırarak istikrarı desteklemekte ve alternatif enerji kaynaklarının geliştirilmesi yönündeki çabaları teşvik etmektedir (Gillissen vd., 2019). Ancak, doğal gazın yaygın kullanımı beraberinde bazı zorlukları da getirmektedir. Özellikle kaynak dağılımı, enerji arzı ve talebi dengesi gibi konularda stratejik planlama gerekmektedir (Villicaña-García ve Ponce-Ortega, 2019; Goodell vd., 2023). Doğal gaz fiyatının zaman serisi tahmini enerji sektörü ve ekonomi açısından büyük önem taşımaktadır. Doğal gaz fiyatı zaman serisi tahminleri, enerji sektöründe stratejik kararların alınmasında ve işletme süreçlerinin yönetilmesinde hayati bir rol oynamaktadır (Khan, 2018). Bu tahminler, enerji şirketlerinin risk yönetimi, tedarik zinciri planlaması ve maliyet kontrolü gibi alanlarda etkili olmasını sağlamaktadır. Ayrıca yatırım kararlarının yapılması, temiz enerji geçişi sürecinin yönetimi, politika oluşturulması ve rekabetçilik analizleri gibi alanlarda da kritik bir öneme sahiptir (Farrokhifar vd., 2020; Gürsan ve Gooyert, 2021). Ancak, doğal gaz fiyatlarındaki dalgalanmaların etkisi, güvenilir tahminlerin sağlanması için ileri düzeyde makine öğrenmesi, yapay zekâ ve optimizasyon tekniklerinin kullanımını ön plana çıkartmaktadır.

Literatür incelendiğinde doğal gaz fiyatının tahmini için makine öğrenimi algoritmalarının kullanımının giderek popüler hale geldiği görülmektedir. Yapılan bir çalışmada Yapay Sinir Ağları (ANN), Destek Vektör Makineleri (SVM), Gradyan Artırma Makineleri (GBM) ve Gaussian Süreç Regresyonu (GPR) gibi yaygın makine öğrenimi araçlarına dayalı tahmin modelleri kıyaslanmıştır (Su vd., 2019). Model eğitimi için çapraz doğrulama yöntemi kullanılmış ve Ocak 2001'den Ekim 2018'e kadar olan aylık Henry Hub doğal gaz spot fiyat verileri değerlendirilmiştir. Sonuçlar, bu dört makine öğrenimi yönteminin doğal gaz fiyatlarını tahmin etmede farklı performans sergilediğini göstermektedir. Ancak genel

olarak, ANN'in SVM, GBM ve GPR'ye kıyasla daha iyi bir tahmin performansı ortaya koyduğu görülmüştür (Su vd., 2019). Bir başka çalışmada doğal gaz fiyatlarının daha güvenilir bir şekilde tahmin edilmesi amacıyla Varyasyonel Kip Ayırıştırma (VMD) ve Topluluk Ampirik Kip Ayırıştırma (EEMD) yöntemlerini birleştirerek, VMD'den sonra kalan artık terimi (Res) EEMD ile ayırmaktadır (Zhan ve Tang, 2022). Daha sonra, bu ayrıştırılmış veriler Uzun-Kısa Süreli Bellek (LSTM) tahmin modeli ile birleştirilerek VMD-EEMD-Res-LSTM adı verilen yeni bir hibrit model oluşturulmuştur (Zhan ve Tang, 2022). Bu modelde mevcut ayırıştırma teknolojileri ile LSTM modelini birleştirildiği ve VMD'den sonra kalan artık terimdeki önemli bilgilerin göz ardı edilmediği için diğer ayırıştırma yaklaşımlarından farklı olduğu belirtilmiştir. Modelin tahmin performansını doğrulamak için, ABD'deki doğal gaz spot fiyat verileri kullanılarak çok adımlı bir ampirik karşılaştırma analizi yapılmıştır. Sonuçlar, önerilen yeni hibrit modelin önemli tahmin avantajlarına sahip olduğunu göstermektedir (Zhan ve Tang, 2022). Li vd. (2021) tarafından aylık Henry Hub doğal gaz fiyatının tahmin edilmesi için VMD, Parçacık Sürü Optimizasyonu (PSO) ve Derin İnanç Ağları (DBN) ile entegre edilmiş hibrit bir model önerilmiştir. Bunun yanında doğal gaz fiyatını uzun vadeli olarak etkileyen faktörler incelenerek bu faktörlerin tahmin performansına katkı sağladığı belirtilmiştir. Yapılan deneysel sonuçlar, önerilen hibrit modelin geleneksel yöntemlere göre daha yüksek tahmin doğruluğuna sahip olduğunu ortaya çıkartmıştır. Özellikle, doğal gaz tüketimi, Amerikan Batı Texas (WTI) ham petrol spot fiyatları, aşırı sıcak ve soğuk hava durumlarının doğal gaz fiyat tahminlerinde belirgin etkileri olduğu belirtilmektedir. Mittakola vd. (2024) tarafından doğal gaz tahmini için veri odaklı modellerden Destek Vektör Regresyonu (SVR), LSTM ve modifiye edilmiş veri odaklı model olan Geliştirilmiş Desen Dizisi Benzerlik Araması (IPSS) yaklaşımı olmak üzere üç yaygın model tanıtılmaktadır. Bu üç model temel alınarak ağırlıklı hibrit veri odaklı model önerilmektedir. Modelin eğitimi için, Haziran 2018 öncesinde ABD'deki günlük doğal gaz spot fiyatlarıyla ilgili veriler kullanılmakta ve modelin tahmin yeteneği Haziran 2018'den Mayıs 2019'a kadar olan verilerle test edilmektedir. Önerilen yeni IPSS modelinin günlük doğal gaz fiyatlarını doğru bir şekilde tahmin edebildiği gösterilmektedir. Duan vd. (2023) tarafından doğal gaz fiyatlarının tahminine katkıda bulunan yeni bir hibrit model önerilmektedir. Uyarlanabilir Gürültü ile Komple Topluluk Ampirik Kip Ayırıştırması (CEEMDAN), Birlikte Çalışma Torbalama (Bagging) yaklaşımı ile entegre edilen Harris Hawks Optimizasyonu (HHO) ve SVR gibi yöntemleri birleştiren yeni bir hibrit model geliştirilmektedir. Aylık Henry Hub doğal gazı tahmini için önerilen yöntemin zaman serisini tahmin etmede daha etkili olduğu gösterilmektedir. Saghi ve Rezaee (2021) tarafından doğal gaz fiyatlarının tahminine yönelik girdi ve hedef vektörleri arasındaki Öklid Mesafesi'ne dayalı yeni bir yaklaşım kullanılarak

optimal zaman gecikmeleri belirlenmektedir. Daha sonra veri setindeki gürültüyü azaltmak amacıyla dalgacık ayrıştırması yöntemi uygulanmaktadır. Ayrıca, zaman serisindeki belirsizliği modellemek için farklı üyelik fonksiyonlarına sahip bulanık dönüşüm yöntemi kullanılmaktadır. Dalgacık ayrıştırması ve bulanık dönüşüm yöntemleri, verinin ön işleme aşamasında birleştirilmektedir. Çeşitli sinir ağlarının çıktılarını entegre etmek için birlikte çalışma yöntemi kullanılmakta ve elde edilen sonuçlar önerilen ön işleme yöntemlerinin doğal gaz fiyat tahminindeki doğruluğu artırdığını göstermektedir.

Bu çalışmada, Elman Sinir Ağları (ENN) ile tahmin modeli oluşturularak doğal gaz fiyatının bir gün sonra alacağı değerin tahmini yapılmıştır. ENN'de gizli katman nöron sayısı ve bias değerlerinin eğitim aşamasında bulunması için optimizasyon yöntemleri kullanılmıştır. Yusufçuk Optimizasyon Algoritması (DOA) yaklaşımı, Genetik Algoritma (GA) ile kıyaslandığında olası modeller içerisinde hata değeri düşük, tahmin başarımı yüksek

olan modelin bulunması sağlanmıştır. Oluşturulan hibrit modelin performansını ölçmek için istatistiksel ölçütlerden Ortalama Kare Hatası (MSE), Ortalama Karekök Sapma Hatası (RMSE) ve Pearson korelasyon katsayısı kullanılmıştır. Devam eden kısımlarda oluşturulan model ve alınan sonuçlar hakkında detaylı bilgi verilmiştir.

## 2. Materyal ve Yöntem

Bu bölümde, doğalgaz fiyatının tahmini için kullanılan veri seti, yapay zekâ yöntemlerinden ENN ve optimizasyon yaklaşımı olarak DOA yaklaşımı detaylı bir şekilde açıklanmıştır.

### 2.1. Veri Seti

Bu çalışmada 01,06,2009-31,05,2024 tarihleri arasında 3986 adet kapanış fiyatı içeren doğal gaz zaman serisi kullanılmıştır (Anonymous, 2024). Şekil 1'de doğalgaz zaman serisinin her yılın başlangıcına dikine çizgiler eklenmiş ve farklı renkte renklendirilmiş şekilde çizdirilmiştir.



Şekil 1. Doğalgaz kapanış fiyatının zamana göre değişimi.

Tablo 1'de doğalgaz zaman serisi için yıllara göre hesaplanan en düşük, en yüksek, ortalama değer, standart sapma, çarpıklık ve basıklık gibi istatistiksel değerler verilmiştir.

Yıllara göre doğalgaz kapanış fiyatının dağılım grafiği ise Şekil 2'deki gibi verilmiştir. Devam eden kısımlarda hibrit modelin kısımları daha detaylı açıklanmıştır.

### 2.2. Elman Sinir Ağları

Elman Sinir Ağları (ENN) Jeffrey L. Elman tarafından önerilmiş bir tür tekrarlayan sinir ağıdır (Elman, 1990). ENN'ler zaman içinde sıralı verilerle çalışabilen ve veri kalıplarındaki zaman bağımlılığını öğrenebilen ağlar olarak tanımlanmıştır. Geleneksel ileri beslemeli sinir ağındaki gibi giriş katmanı, gizli katman ve çıkış katmanından oluşmaktadır. Farklı olarak gizli katmanın çıkışından bir geri besleme mekanizmasına sahiptir. Bu kısım bağlam katmanı (context layer) ile kurulmaktadır. Bu mekanizma ile ağıın önceki zaman adımlarındaki

bilgiyi hatırlamasına ve bu bilgiyi mevcut zaman adımındaki hesaplamalarda kullanmasına olanak tanınmaktadır. Bağlam katmanı gizli katmanın çıkışını bir sonraki zaman adımına girdi olarak taşımakta ve bir bellek elemanı rolü oynamaktadır. Bu bağlantı yöntemi ile ağ tarihsel verilere duyarlı hale gelmektedir (Elman, 1990; Liu vd., 2023). Şekil 3'te ENN'nin genel topolojisi gösterilmektedir. ENN modeli eşitlik 1'deki gibi tanımlanmaktadır.

$$y(k) = g(\omega_3 x(k) + b_2) \quad (1)$$

Burada  $y$  çıkış katmanının düğüm vektörü,  $x$  gizli katmanının düğüm vektörünü,  $\omega_3$  gizli katman ve çıkış katmanı arasındaki ağırlık katsayılarını,  $b_2$  gizli katman eşik değerlerini,  $g$  aktivasyon fonksiyonunu ifade etmektedir. Gizli katman düğüm vektörü  $x$  ise eşitlik 2'deki gibi tanımlanmaktadır.

$$x(k) = f(\omega_1 x_c(k) + \omega_2 (u(k-1)) + b_1) \quad (2)$$


Burada  $x_c$  geribesleme durum vektörünü,  $u$  giriş vektörünü,  $\omega_1$  bağlam katmanı ve gizli katman arasındaki ağırlık katsayılarını,  $\omega_2$  giriş katmanı ve gizli katman arasındaki ağırlık katsayılarını,  $b_1$  giriş katmanı eşik

değerlerini,  $f$  aktivasyon fonksiyonunu ifade etmektedir. Geribesleme durum vektörü ise gizli katman düğüm vektörünün önceki değerleri olacak şekilde eşitlik 3'teki gibi ifade edilmektedir.


$$x_c(k) = x(k-1) \quad (3)$$

**Tablo 1.** Doğalgaz zaman serisi için yıllara göre hesaplanan istatistiksel değerler

Yıllar	En Düşük	En Yüksek	Ortalama	Standart Sapma	Çarpıklık	Basıklık
2009	2,51	5,99	4,1643	0,8195	0,1804	-0,7766
2010	3,33	6,01	4,3931	0,5600	0,8071	0,1379
2011	2,96	5,01	4,1061	0,4693	-0,2940	-0,6023
2012	1,90	3,91	2,8401	0,5037	0,3236	-0,8672
2013	3,13	4,53	3,7420	0,3285	0,3741	-0,6076
2014	2,91	5,47	4,2515	0,4331	-0,2117	0,0437
2015	1,74	3,31	2,6285	0,2679	-0,9924	0,8974
2016	1,63	3,87	2,5628	0,5365	0,2886	-0,7725
2017	2,61	3,72	3,0267	0,1805	0,2998	0,1587
2018	2,56	4,68	3,0604	0,4852	1,8846	2,8091
2019	2,08	3,56	2,5263	0,2742	0,8226	0,9597
2020	1,52	3,38	2,1595	0,4611	0,6543	-0,8084
2021	2,45	6,32	3,7298	1,0358	0,6534	-0,7830
2022	3,75	9,73	6,5483	1,5743	0,0170	-1,0304
2023	2,01	4,14	2,7020	0,4046	0,9508	0,6708
2024	1,59	3,32	2,1187	0,4261	0,9432	-0,1938



**Şekil 2.** Yıllara göre doğalgaz kapanış fiyatının dolar bazlı dağılım grafiği.




Şekil 3. Elman Sinir Ağlarının genel topolojisi (Elman, 1990; Zhou vd., 2023).

### 2.3. Yusufçuk Optimizasyon Algoritması

Yusufçuk sineği, büyük birleşik gözleri, güçlü saydam kanatları, göz alıcı renkleri ve uzun vücutlarıyla tanınan bir böcek türüdür. Dünya genelinde çok farklı türleri bulunmaktadır. Yaşam döngüsü larva ve yetişkin olmak üzere iki evreden oluşmaktadır. Avlanma sırasında zeki ve nadir davranışlar sergilemektedirler. Statik sürülerde küçük gruplar halinde uçup avlanmak için ileri geri hareket etmektedirler. Dinamik sürülerde ise çok sayıda yusufçuk, büyük gruplar halinde göç için uzun yolculuklar yapmaktadırlar (Mirjalili, 2016).

Reynolds'a göre, sürülerin davranışları ayrılma, hizalanma ve birliktelik olmak üzere üç temel ilkeyi takip etmektedir (Reynolds, 1987; Mirjalili, 2016). Sürülerin ana hedefi hayatta kalmak olduğundan, bireyler genellikle yiyecek kaynaklarına çekilirken dışarıdaki tehditlerden kaçınmaya yönelmektedirler. Bu iki temel davranış göz önüne alındığında, Şekil 4'teki gibi bireylerin hayatta kalma ve etkili iş birliği için bir yiyecek kaynağına doğru çekim ve düşmanın dikkatini dağıtma gibi faktörlerde göz önüne alındığında beş ana davranış söz konusudur.



Şekil 4. Sürülerdeki bireylerin konum güncellemelerinde beş davranış kalıbı. a. ayrılma b. hizalanma c. birliktelik d. bir yiyecek kaynağına doğru çekim e. düşmanın dikkatini dağıtma (Mirjalili, 2016).

Her bir davranış matematiksel olarak eşitlik 4-8'deki gibi modellenmektedir (Reynolds, 1987; Mirjalili, 2016). Ayrılma, sürü içindeki bireylerin komşuluklarındaki diğer bireylerden statik olarak çarpışmayı önlemeye çalışmalarını ifade etmektedir. Başka bir ifadeyle, bireylerin birbirlerine yakın olmaktan kaçınarak aralarında güvenli bir mesafe korumalarını sağlayan bir davranıştır. Böylece sürü içindeki her bir birey, çevresindeki diğer bireylerle etkileşime girerken çarpışma riskini minimize etmekte dolayısıyla sürünün

genel güvenliğini ve düzenini sağlamaya yardımcı olmaktadır. Ayrılma matematiksel olarak eşitlik 4'teki gibi ifade edilmektedir.

$$S_i = -\sum_{j=1}^N X - X_j \quad (4)$$

Burada  $X$  mevcut bireyin konumunu,  $X_j$  ise  $j$ . komşu bireyin konumunu ve  $N$  komşu bireylerin sayısını göstermektedir. Hizalanma, sürü içindeki her bireyin, çevresindeki diğer bireylerin hareket yönü ve hızına yakın bir şekilde hareket etmesi olarak ifade

edilmektedir. Bu davranış, bireyler arasında birliği ve koordinasyonu sağlayarak sürünün etkili bir şekilde hareket etmesini ve grup hedeflerine ulaşmasını kolaylaştırmaktadır. Hizalanma eşitlik 5'teki gibi ifade edilmektedir.

$$A_i = \frac{\sum_{j=1}^N V_j}{N} \quad (5)$$

Bu denklemde  $V_j$  komşu bireylerin hızını göstermektedir. Birliktelik, sürü içindeki bireylerin komşuluklarındaki diğer bireylerin ağırlık merkezi yönünde eğilim gösterme durumunu ifade etmektedir. Bir başka ifadeyle, bir bireyin bulunduğu çevredeki diğer bireylerin bulunduğu alanın merkezine doğru çekilme eğilimi olarak bu davranış tanımlanmaktadır. Böylece sürü içindeki her bir birey, sürünün bütünlüğünü korumak ve grup içinde birliği sağlamak için yakınlaşma ve bir araya gelme eğilimindedir. Birliktelik ise matematiksel olarak eşitlik 6'daki gibi ifade edilmektedir.

$$C_i = \frac{\sum_{j=1}^N X_j}{N} - X \quad (6)$$

Bir besin kaynağına doğru çekim ise eşitlik 7'deki gibi ifade edilmektedir.

$$F_i = X^+ - X \quad (7)$$

Burada  $X^+$  yiyecek kaynağının konumunu göstermektedir. Düşmanın dikkatini dağıtma ise matematiksel olarak eşitlik 8'deki gibi verilmektedir.

$$E_i = X^- + X \quad (8)$$

Burada  $X^-$  düşmanın konumunu göstermektedir. Yapay yusufoçukların bir arama alanındaki konumlarını güncellemek ve hareketlerini simüle etmek için iki vektör dikkate alınmaktadır. Bunlar adım ( $\Delta X$ ) ve konum ( $X$ ) olarak tanımlanmaktadır. Adım vektöründe, PSO algoritmasındaki hız vektörü temel alınmıştır. PSO'daki hız vektörüne benzer şekilde eşitlik 9'daki gibi yusufoçukların hareket yönü beş temel ilkenin kombinasyonu olarak ifade edilmektedir.

$$\Delta X_{t+1} = (sS_i + aA_i + cC_i + fF_i + eE_i) + w\Delta X_t \quad (9)$$

Burada  $s$ , ayrılma ağırlığını,  $S_i$ , i. bireyin ayrılmasını,  $a$

hizalanma ağırlığını,  $A_i$ , i. bireyin hizalanmasını,  $c$ , birliktelik ağırlığını,  $C_i$ , i. bireyin birlikteliğini,  $f$ , yiyecek faktörünü,  $F_i$ , i. bireyin yiyecek kaynağını  $e$ , düşman faktörünü,  $E_i$ , i. bireyin düşmanın konumunu ifade etmektedir. Pozisyon vektörü ise eşitlik 10'daki gibi hesaplanmaktadır.

$$X_{t+1} = X_t + \Delta X_{t+1} \quad (10)$$

Rastgeleliği, stokastik davranışı ve yapay yusufoçukların keşif özelliklerini geliştirmek amacıyla, komşu çözümler olmadığında arama alanında rastgele yürüyüş (Lévy uçuşu) kullanarak dolaşmaları gerekmektedir. Bu yöntem, yusufoçukların daha geniş bir arama alanını keşfetmelerine ve daha etkili çözümler bulmalarına olanak tanımaktadır. Bu durumda, yusufoçukların pozisyonları eşitlik 11'deki gibi güncellenmektedir.

$$X_{t+1} = X_t + Lévy(d) \times X_t \quad (11)$$

Lévy uçuşu ise eşitlik 12'deki gibidir.

$$Lévy(x) = 0,01 \times \frac{r_1 \times \sigma}{|r_2|^{\beta}} \quad (12)$$

Burada  $r_1$  ve  $r_2$   $[0, 1]$  aralığında iki rastgele sayı,  $\beta$  ise bir sabit olmak üzere  $\sigma$  eşitlik 13'teki gibi hesaplanmaktadır.

$$\sigma = \left( \frac{\Gamma(1+\beta) \times \sin\left(\frac{\pi\beta}{2}\right)}{\Gamma\left(\frac{1+\beta}{2}\right) \times \beta \times 2^{\left(\frac{\beta-1}{2}\right)}} \right)^{(1/\beta)} \quad (13)$$

Yusufoçuk Optimizasyon Algoritması (DOA'nda verilen, optimizasyon problemi için hesaplamaya rastgele çözümler seti oluşturularak başlanmaktadır. Bu süreçte, yusufoçukların konum ve adım vektörleri, değişkenlerin alt ve üst sınırları içinde rastgele değerlerle başlatılmaktadır. Her yinelemede, her yusufoçukun konumu ve adımı eşitlik 10, 11 ve 12 kullanılarak güncellenmektedir.  $X$  ve  $\Delta X$  vektörlerini güncellemek için, her yusufoçukun komşuluğu, tüm yusufoçuklar arasındaki Öklid mesafesi hesaplanarak ve  $N$  tanesi seçilerek belirlenmektedir. Konum güncelleme süreci, bitiş kriteri karşılanana kadar devam etmektedir. DOA'nın sözde kodu Şekil 5'te verilmiştir.

Algoritma: DOA'nın sözde kodu.

1. **Initialization:** Yusufoçuk popülasyonunu başlat  $X_i(i = 1, \dots, N)$
2. Adım vektörlerini başlat
3. **while** Bitirme koşulu sağlanana kadar devam et
  - Tüm yusufoçukların amaç değerlerini hesapla
  - Yiyecek kaynağını ve düşmanı güncelle
  - $w, s, a, c, f$  ve  $e$  değerlerini güncelle
  - Denklem 4 ile 8 kullanılarak  $S, A, C, F$  ve  $E$  değerlerini hesapla
  - Komşuluk yarıçapını güncelle
  - **if** Bir yusufoçukun en az bir komşu yusufoçuğu varsa
    - i. Denklem 9 kullanılarak hız vektörünü güncelle
    - ii. Denklem 10 kullanılarak konum vektörünü güncelle
  - **else**
    - i. Denklem 11 kullanılarak konum vektörünü güncelle
  - Eğer yeni konumlar sınırların dışındaysa, yeni konumları kontrol et ve düzelt
  - **end if**
4. **end while**

Şekil 5. DOA'nın sözde kod gösterimi (Mirjalili, 2016).

## 2.4. Genetik Algoritma

Genetik Algoritma (GA), biyolojik evrim süreçlerinden ilham alınarak optimizasyon problemlerini çözmek için kullanılan bir yöntemdir (Holland, 1992). GA, bir popülasyon içindeki bireylerin evrimleşerek daha iyi çözümler üretmesini sağlamaktadır. Bu süreçte, her bir birey genetik bir yapı ile temsil edilmekte ve doğal seçim, çaprazlama ve mutasyon gibi genetik operatörler kullanılarak yeni nesiller oluşturulmaktadır. Doğal seçim, en iyi uyum sağlayan bireylerin bir sonraki jenerasyona seçilmesini sağlarken, çaprazlama ve mutasyon, genetik çeşitliliği artırarak çözüm uzayını daha etkili bir şekilde taramaktadır (Holland, 1992). Çalışmada DOA yaklaşımı ile kıyaslamak amacıyla GA yöntemi kullanılmaktadır.

## 2.5. Performans Metrikleri

Bu çalışmada MSE, RMSE ve Pearson korelasyon katsayısı performans metrikleri olarak kullanılmıştır. MSE, her bir tahminin gerçek değerden olan farkının karesi alınarak bu karelerin ortalamasını hesaplayan bir ölçüm yöntemidir. MSE formülü eşitlik 14'te verilmiştir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2 \quad (14)$$

RMSE ise gerçek değerlerle tahmin edilen değerler arasındaki farkların karelerinin ortalamasının karekökü alınarak hesaplanmaktadır. eşitlik 15'teki gibi hesaplanmaktadır.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2} \quad (15)$$

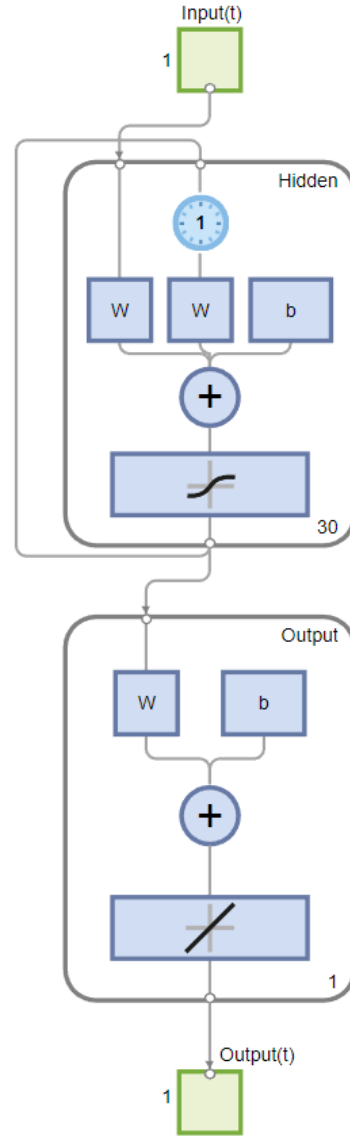
Pearson korelasyon katsayısı iki değişken arasındaki ilişkinin gücünü ve yönünü ölçen istatistiksel bir ölçüdür. eşitlik 16'daki gibi hesaplanmaktadır. Burada  $\hat{x}_i$  ve  $\hat{y}_i$  sırasıyla gerçek ve tahmin edilen zaman serisinin ortalama değeri olarak hesaplanmaktadır.

$$R = \frac{\sum_{i=1}^n (x_i - \hat{x}_i)(y_i - \hat{y}_i)}{\sqrt{\sum_{i=1}^n (x_i - \hat{x}_i)^2} \sqrt{\sum_{i=1}^n (y_i - \hat{y}_i)^2}} \quad (16)$$

## 3. Bulgular ve Tartışma

Benzetim çalışması MATLAB ortamında gerçekleştirilmiştir. Öncelikle Şekil 6'daki gibi ENN modeli oluşturulmuştur.

Burada örnek olarak gecikme sayısı 1, gizli katman nöron sayısı 30 olan bir ENN modelinin MATLAB ortamında temsili çizimi verilmiştir. Benzetim çalışmasında gizli katman nöron sayısı 3 ile 30 arasında değiştirilmiştir. Veri seti %70 eğitim, %15 doğrulama ve %15 test olmak üzere ayrılmıştır. Benzetim çalışması 20 kez tekrar edilmiştir. ENN modelinin eğitimi aşamasında model ağırlık ve bias değerleri kıyaslama yöntemi olarak Genetik Algoritma (GA) ile bulunmuştur. Tablo 2'deki ağırlık ve bias değerleri dikkate alındığında gizli katman nöron sayısı (M) değerine bağlı olarak bireyler  $M^2+3M+1$  adet değerden oluşmaktadır. DOA yaklaşımı içinde aynı değerler optimize edilmektedir.



Şekil 6. Oluşturulan ENN'nin MATLAB programında görüntüsü.

Tablo 2. GA ve DOA için gizli katman nöron sayısına bağlı olarak popülasyondaki bireylerin ağırlık ve bias değerleri

M <sup>2</sup> Adet	M Adet	M Adet	M Adet	1 Adet
$\omega_1$	$\omega_2$	$\omega_3$	$b_1$	$b_2$


ENN+GA yöntemi için jenerasyon sayısı 200 popülasyon büyüklüğü 100 olacak şekilde çalıştırılmıştır. GA'da çaprazlama oranı 0,80, mutasyon oranı 0,20 olarak seçilmiştir. GA'da Rulet tekerleği seçme yaklaşımı kullanılmıştır. Bunun dışında çalışmada önerilen hibrit tahmin sisteminin bir parçası olan DOA yaklaşımı ile farklı parametreler araştırılarak en iyi modelin bulunması için parametre optimizasyonu sağlanmıştır. Popülasyonda yusufçukların konumları rastgele olarak belirlenmektedir. Başlangıçta belirlenen yusufçukların temel alındığı her jenerasyonda yarıçaplar dinamik olarak güncellenmektedir. Maksimum ve minimum aralık arasındaki farkın dörtte biri alınarak başlamakta ve jenerasyon ilerledikçe bu değer artmaktadır. PSO'dan

esinlenen atalet ağırlığı  $w$  ise başlangıç değeri olarak 0,90 değeri kullanılmakta ve jenerasyon ilerledikçe bu değeri 0,40 olmaktadır. Bir adet kontrol parametresi  $c$  ve atalet ağırlığı  $w$ 'ye bağlı olarak beş ana davranışın ağırlığı hesaplanmaktadır. Bu dinamik parametrelerin dışında yusufçuk popülasyonu GA'daki popülasyon sayısı ile benzer şekilde 100 olmakta ve jenerasyon 200 olana kadar benzetim devam etmektedir. ENN+GA ve ENN+DOA hibrit yöntemlerin uygunluk fonksiyonu ise RMSE'nin minimizasyonunu ifade edecek şekilde eşitlik 17'deki gibi verilmiştir.


$$Uygunluk\ deęeri = \min\left(\sqrt{\frac{1}{n}\sum_{i=1}^n(x_i - y_i)^2}\right) \quad (17)$$

ENN için Şekil 7'de gizli katman nöron sayısının değişimine ve tekrar edilen eğitim sayısına göre hata değerinin değişiminin üç boyutlu grafiği çizdirilmiştir.

Tekrarlama sonucunda beklenildiği gibi çok farklı aralıklarda hata değerleri ile karşılaşmıştır. Bu görüntüyü daha sade bir biçimde ifade etmek amacıyla Şekil 8'deki gibi kutu bilyık grafiği ile tekrarlama sonucunda her bir gizli katman nöron sayısı için oluşturulan modelin RMSE dağılımı gösterilmektedir. Bu dağılım incelendiğinde nöron sayısının artışı ile hata değerinin değişimi arasında genel bir trend eğilimi görülmemektedir. En düşük hata değerleri 11, 14, 16, 23, 27 ve 30 gizli katman nöron sayısı için elde edilmiştir. Nöron sayısı arttıkça aykırı değerlerin arttığı söylenebilir. Buda, Momentuma Sahip ve Adaptif Öğrenme Hızlı Gradyan İnişi (GMALR) eğitim yaklaşımının kullanıldığı modelin eğitim sürecinde beklenmedik şekilde yüksek hatalar üretebileceğini göstermektedir.



Şekil 7. ENN yöntemi için gizli katman nöron sayısının değişimine göre tekrar edilen eğitim sayısı için RMSE değışimi.

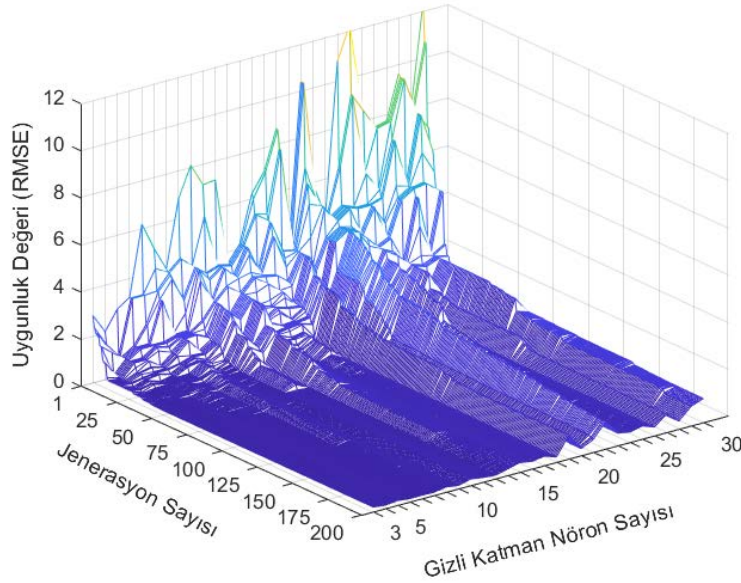


Şekil 8. ENN yöntemi için gizli katman nöron sayısının değişimine göre tekrar edilen eğitim sayısı için RMSE değışiminin kutu bilyık grafiği ile gösterimi.




ENN+GA ve ENN+DOA yöntemleri için gizli katman nöron sayısının değişimine göre jenerasyon boyunca RMSE değişimi Şekil 9 ve Şekil 10'daki üç boyutlu yüzey grafik ile çizdirilmiştir. Üç boyutlu yüzey grafiklerinde gizli katman nöron sayısı, jenerasyon sayısı ve uygunluk değeri sırasıyla x, y ve z eksenlerinde temsil edilmektedir. Şekil 9'daki ENN+GA için yüzey grafiği incelendiğinde x ekseninde gizli katman nöron sayısı 3'ten 30'a kadar artırıldığında belirli bir noktaya kadar RMSE değerlerinde bir azalma trendi gözlemlenebilmektedir. Ancak, nöron sayısı arttıkça RMSE değerleri arasındaki dalgalanmalar da artmaktadır. Özellikle jenerasyonun ilk başlangıcında RMSE değerleri nispeten artış gösterdiği görülmektedir. y ekseninde jenerasyon sayısı 1'den 200'e kadar arttıkça yani GA ile ENN daha fazla evrim geçirdikçe genel olarak RMSE değerlerinde bir azalma görülmektedir. Burada z eksenindeki RMSE değerleri optimizasyonda minimizasyonu amaçlayan uygunluk değerini temsil etmektedir. Daha düşük RMSE değerleri, modelin tahmin performansının daha iyi olduğunu göstermektedir. Grafikte, RMSE değerlerinin genel olarak düşük seviyelerde seyrettiği ve zamanla azaldığı gözlemlenmektedir. Ancak bazı bölgelerde ani yükselmeler ve dalgalanmalar da dikkat çekmektedir. Genel eğilimlerden bahsedilecek olursa ilk 1-50 jenerasyonda başlangıçta RMSE değerleri genellikle daha yüksektir ve daha fazla dalgalanma görülmektedir.


Jenerasyon sayısı arttıkça genel olarak 50'den sonra, RMSE değerlerinde belirgin bir azalma eğilimi gözlemlenmektedir. Gizli katman nöron sayısı arttıkça, özellikle 15-30 aralığında, RMSE değerlerinde dalgalanmalar artmakta, ancak genel olarak düşük RMSE değerleri jenerasyon sayısı arttıkça elde edilmektedir. ENN'de gizli katman nöron sayısı arttıkça model karmaşıklığı artmakta ve bununla birlikte düşük nöron sayısına göre hata değerinin arttığı görülmektedir. Şekil 10'daki ENN+DOA yöntemi için gizli katman nöron sayısının değişimine göre jenerasyon boyunca RMSE değişimi incelendiğinde ENN+GA yöntemine kıyasla başlangıçta RMSE değerleri düşük modellerin elde edildiği görülmektedir. 1-50 jenerasyon aralığında dalgalanma miktarı yüksek olmakla birlikte tüm gizli katman nöron sayısı boyunca 50'den sonraki jenerasyonlarda düşük seviyelerde seyrettiği görülmüştür. ENN+GA'ya göre ENN+DOA yönteminde dalgalanma miktarının düşük kaldığı söylenebilir. ENN+GA yaklaşımı ile elde edilen RMSE değerlerinin ENN ile benzer olduğunu ve aykırı değerlerin çokça görüldüğü, gizli katman nöron sayısının değişimine göre jenerasyon boyunca uygunluk değeri olan RMSE değişiminin kutu bıyık grafiği Şekil 11'de incelenmesi ile ortaya çıkmaktadır. Buna paralel bir inceleme olarak ENN+DOA yaklaşımında ise aykırı değerler elde edilmekle birlikte diğer yöntemlere oranla daha düşük kaldığı görülmüştür.



Şekil 9. ENN+GA yöntemi için gizli katman nöron sayısının değişimine göre jenerasyon boyunca RMSE değişimi.



Şekil 10. ENN+DOA yöntemi için gizli katman nöron sayısının değişimine göre jenerasyon boyunca RMSE değişimi.



Şekil 11. ENN+GA ve ENN+DOA yöntemlerinin gizli katman nöron sayısının değişimine göre jenerasyon boyunca uygunluk değeri olan RMSE değişiminin kutu bıyık grafiği.

20 kere tekrar eden benzetim çalışması sonucunda Tablo 3'teki gibi ENN, ENN+GA ve ENN+DOA yaklaşımlarının MSE, RMSE ve R değerleri birlikte verilmiştir. Tablodaki değerler incelendiğinde ENN modeli için istatistiksel hata ölçütleri uygulandığında MSE, RMSE ve R ortalama

değerleri 0,0782, 0,2549 ve 0,9518 olarak standart sapma değerleri ise 0,0939, 0,1193 ve 0,0577 olarak bulunmuştur. ENN+GA modeli için ise MSE, RMSE ve R ortalama değerleri 0,0425, 0,1928 ve 0,9739 olarak standart sapma değerleri ise 0,0372, 0,0748 ve 0,0229

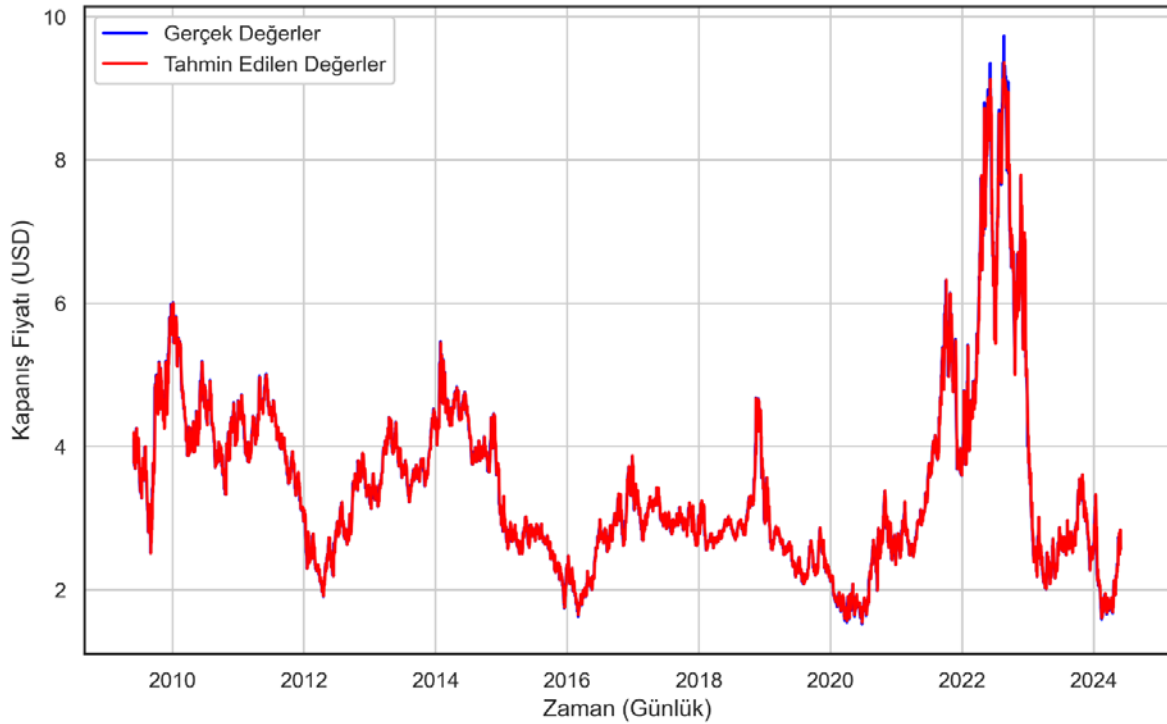
olarak bulunmuştur. Son olarak ENN+DOA modeli için MSE, RMSE ve R ortalama değerleri 0,0176, 0,1328 ve 0,9891 olarak standart sapma değerleri ise 0,0013, 0,0046 ve 0,0008 olarak bulunmuştur. Sonuçlar incelendiğinde ENN+DOA yöntemi, MSE, RMSE ve R değerleri açısından ENN ve ENN+GA yöntemlerinden daha iyi performans gösterdiği görülmektedir. Daha düşük hata oranı ve daha yüksek korelasyon katsayısı ile daha doğru doğal gaz kapanış fiyatı tahmini yapıldığı söylenebilir. ENN+GA yöntemi, genellikle ENN yönteminden daha iyi performans göstermektedir, ancak ENN+DOA yöntemi ile kıyaslandığında daha yüksek hata

oranı ve daha düşük korelasyon katsayısı görülmektedir. ENN yöntemi için diğer iki yöntemden daha düşük performans göstermektedir, yüksek MSE ve RMSE değerleri ile daha az doğru tahminler yapıldığı gözlemlenmektedir. ENN+GA, ENN'ye göre R hata metriği için %2,32'lik iyileşme sağlamaktadır. ENN+DOA, ENN+GA'ya göre R hata metriği için %1,56'lık iyileşme sağlamaktadır.

Benzetim sonucunda elde edilen ENN+DOA hibrit modeli için gerçek doğal gaz zaman serisine karşılık tahmin edilen zaman serisi çizimi Şekil 12'deki gibi olmaktadır.

**Tablo 3.** ENN, ENN+GA ve ENN+DOA yaklaşımlarının MSE, RMSE ve R değerleri ile kıyaslanması

Yöntemler	MSE	RMSE	R
ENN	0,0782±0,0939	0,2549±0,1193	0,9518±0,0577
ENN+GA	0,0425±0,0372	0,1928±0,0748	0,9739±0,0229
ENN+DOA	0,0176±0,0013	0,1328±0,0046	0,9891±0,0008



**Şekil 12.** ENN+DOA yaklaşımı ile elde edilen en iyi model için gerçek ve tahmin edilen doğal gaz zaman serisinin çizdirilmesi.

#### 4. Sonuç

Doğal gaz zaman serisi tahmini çalışması ENN ve DOA hibrit modeli ile gerçekleştirilmiştir. Genel olarak belirli bir model yapısının farklı parametre değerleri ile elde edilen sonuçlarına ve bu sonuçların DOA yaklaşımı ile elde edilmesine ve GA ile kıyaslanmasına odaklanılmıştır. Gecikme sayısı 1 ve nöron sayısı 3-30 aralığı için yapılan hesaplamalar sonucunda elde edilen RMSE değeri en düşük ENN+DOA ile elde edilmiştir. Adil olması açısından optimizasyon yöntemleri 200 iterasyon boyunca çalıştırılmıştır. 20 tekrar sonucunda ortalama ve standart

sapma cinsinden performans metrikleri hesaplanmıştır. ENN, ENN +GA ve ENN +DOA modellerinin MSE, RMSE ve R değerleri birbiri ile kıyaslandığında en düşük hata değeri ve en yüksek başarımlı değeri ENN+DOA ile elde edilmiştir. ENN+DOA modeli ile ENN+GA'ya göre R değerinde %1,56'lık iyileşme sağlanmıştır. ENN'ye göre ise ENN+DOA modeli ile R değerine göre %3,91'lik bir iyileşme sağlanmıştır. DOA yaklaşımının kullanılmasıyla en iyi model parametrelerinin belirlenmesi optimizasyon sürecinde başarılı sonuçlar elde etmek için önemli olmaktadır. DOA diğer sezgisel yöntemlerin özelliklerini kullanarak model yapılandırmasını en iyi şekilde

ayarlamayı amaçlamaktadır. Sonuç olarak bu çalışma ile ENN modelinin parametrelerini optimize etmek için DOA'nın etkili bir yöntem olduğunu ve daha iyi performans sağladığını göstermiştir. İlerleyen çalışmalarda, model performansını artırmak için hiper-parametre optimizasyonu üzerine daha derinlemesine odaklanılabilir. Örneğin, yapay sinir ağları modellerinde öğrenme oranı, momentum katsayısı gibi parametrelerin dikkatli bir şekilde optimize edilmesi, modelin eğitim sürecindeki doğruluk ve genelleme kapasitesini artırabilir. Genetik algoritmalar gibi sezgisel yöntemlerde ise çaprazlama ve mutasyon oranları vb. optimize ederek başarıma etkisi incelenebilir. Bunların yanı sıra, farklı zaman dilimlerinde ve mevsimsel etkileri kapsayan daha geniş veri setleriyle çalışmalar yapılarak modelin tahmin gücü artırılabilir. Böylece, modelin yalnızca bir dönem veya sınırlı bir zaman dilimi için değil, çeşitli dönemler için de genellenebilir hale gelmesi sağlanabilir. Bu şekilde, çalışmanın doğruluğu ve güvenilirliği dahada artırılarak kapsamlı katkılar sağlanabilir.

## Katkı Oranı Beyanı

Yazarın katkı yüzdeleri aşağıda verilmiştir. Yazar makaleyi incelemiş ve onaylamıştır.

	S.K.
K	100
T	100
Y	100
VTI	100
VAY	100
KT	100
YZ	100
KI	100
GR	100
PY	100
FA	100

K= kavram, T= tasarım, Y= yönetim, VTI= veri toplama ve/veya işleme, VAY= veri analizi ve/veya yorumlama, KT= kaynak tarama, YZ= Yazım, KI= kritik inceleme, GR= gönderim ve revizyon, PY= proje yönetimi, FA= fon alımı.

## Çatışma Beyanı

Yazar bu çalışmada hiçbir çıkar ilişkisi olmadığını beyan etmektedirler.

## Etik Onay Beyanı

Bu çalışmada hayvanlar ve insanlar üzerinde herhangi bir çalışma yapılmadığı için etik kurul onayı alınmamıştır.

## Kaynaklar

- Afgan NH, Pilavachi PA, Carvalho MG. 2007. Multi-criteria evaluation of natural gas resources. *Energy Policy*, 35(1): 704-713.
- Anonymous. 2024. Natural Gas Price. URL: <https://www.investing.com/commodities/natural-gas> (accessed date: 31 May 2024).
- Duan Y, Zhang J, Wang X. 2023. Henry Hub monthly natural gas price forecasting using CEEMDAN-Bagging-HHO-SVR. *Front Energy Res*, 11: 1323073.
- Elman JL. 1990. Finding structure in time. *Cogn Sci*, 14(2): 179-211.
- Farrokhifar M, Nie Y, Pozo D. 2020. Energy systems planning: A survey on models for integrated power and natural gas networks coordination. *Appl Energy*, 262: 114567.
- Gillessen B, Heinrichs H, Hake JF, Allelein HJ. 2019. Natural gas as a bridge to sustainability: Infrastructure expansion regarding energy security and system transition. *Appl Energy*, 251: 113377.
- Goodell JW, Gurdgiev C, Paltrinieri A, Piserà S. 2023. Global energy supply risk: Evidence from the reactions of European natural gas futures to Nord Stream announcements. *Energy Econ*, 125: 106838.
- Gürsan C, de Gooyert V. 2021. The systemic impact of a transition fuel: Does natural gas help or hinder the energy transition?. *Renew Sustain Energy Rev*, 138: 110552.
- Holland JH. 1992. Genetic algorithms. *Sci Am*, 267(1): 66-73.
- Khan MI. 2018. Evaluating the strategies of compressed natural gas industry using an integrated SWOT and MCDM approach. *J Clean Prod*, 172: 1035-1052.
- Khan MI, Yasmin T, Shakoor A. 2015. Technical overview of compressed natural gas (CNG) as a transportation fuel. *Renew Sustain Energy Rev*, 51: 785-797.
- Kong F, Liu Y, Tong L, Guo W, Jin Y, Wang L, Ding Y. 2023. A novel optimization for liquefied natural gas power plants based on the renewable energy. *Appl Therm Eng*, 233: 121172.
- Li J, Wu Q, Tian Y, Fan L. 2021. Monthly Henry Hub natural gas spot prices forecasting using variational mode decomposition and deep belief network. *Energy*, 227: 120478.
- Liu W, Sun J, Liu G, Fu S, Liu M, Zhu Y, Gao Q. 2023. Improved GWO and its application in parameter optimization of Elman neural network. *PLoS One*, 18(7): e0288071.
- Mirjalili S. 2016. Dragonfly algorithm: a new meta-heuristic optimization technique for solving single-objective, discrete, and multi-objective problems. *Neural Comput Appl*, 27: 1053-1073.
- Mittakola RT, Ciais P, Zhou C. 2024. Short-to-medium range forecast of natural gas use in the United States residential buildings. *J Clean Prod*, 437: 140687.
- Reynolds CW. 1987. Flocks, herds and schools: A distributed behavioral model. In: *Proceedings of the 14th annual conference on Computer graphics and interactive techniques*, August 01, Volume 21 ACM, ABD, pp: 25-34.
- Rizvi SKA, Naqvi B, Boubaker S, Mirza N. 2022. The power play of natural gas and crude oil in the move towards the financialization of the energy market. *Energy Econ*, 112: 106131.
- Saghi F, Rezaee MJ. 2021. An ensemble approach based on transformation functions for natural gas price forecasting considering optimal time delays. *PeerJ Comput Sci*, 7: e409.
- Su M, Zhang Z, Zhu Y, Zha D, Wen W. 2019. Data driven natural gas spot price prediction models using machine learning methods. *Energies*, 12(9): 1680.
- Szklo AS, Soares JB, Tolmasquim MT. 2004. Economic potential

- of natural gas-fired cogeneration—analysis of Brazil's chemical industry. *Energy Policy*, 32(12): 1415-1428.
- Villicaña-García E, Ponce-Ortega JM. 2019. Sustainable strategic planning for a national natural gas energy system accounting for unconventional sources. *Energy Convers Manag*, 181: 382-397.
- Zhan L, Tang Z. 2022. Natural gas price forecasting by a new hybrid model combining quadratic decomposition technology and LSTM model. *Math Probl Eng*, 2022(1): 5488053.
- Zhou L, Fan Q, Huang X, Liu Y. 2023. Weak and strong convergence analysis of Elman neural networks via weight decay regularization. *Optim*, 72(9): 2287-2309.