

---

*Araştırma Makalesi / Research Article*

---

## **Diferansiyel Gelişim Algoritma Tabanlı Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi ile Kısa Dönem Rüzgar Hızı Kestirimi**

Emrah DOKUR<sup>1</sup>, Uğur YÜZGEÇ<sup>2</sup>, Mehmet KURBAN<sup>1\*</sup>

<sup>1</sup>Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Elektrik Elektronik Mühendisliği Bölümü, Bilecik, Türkiye

<sup>2</sup>Bilecik Şeyh Edebali Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Bilecik, Türkiye  
(ORCID:0000-0002-4576-1941) (ORCID:0000-0002-5364-6265) (ORCID:0000-0003-2618-2861)

---

### **Öz**

Üretim planlaması ve güç sistemlerinin yönetilmesi açısından rüzgar enerji sistemlerinden üretilecek elektrik enerjisinin belirli periyotlar için tahmin edilmesi gerekmektedir. Bu kapsamda, asimetrik ve kararsız yapıdaki rüzgar hızı verilerinin hassas bir şekilde tahmin edilebilmesi için bir çok farklı rüzgar hızı kestirim yaklaşımları önerilmiştir. Bu çalışma kapsamında, diferansiyel gelişim algoritması (DE) yaklaşımı ile optimize edilen uyarlamalı sinirsel bulanık çıkarım sistemi (ANFIS) kullanılarak kısa dönemli (1 saat) rüzgar hızı tahmin modelleri geliştirilmiştir. Çalışma kapsamında ele alınan yöntemde, diferansiyel gelişim sezgisel yaklaşımı kullanarak model parametreleri kısa dönemli rüzgar hızı tahmini için belirlenmiş ve karşılaştırmalı olarak analiz edilmiştir. Önerilen yaklaşımın tahmindeki performans kriterlerini doğrulamak için Bilecik ilinde bulunan bir gözlem istasyonundaki rüzgar hızı serileri kullanılmıştır. ANFIS model parametrelerinin optimizasyonunda kullanılan sezgisel algoritma 10 kez tekrarlı bağımsız olarak çalıştırılmış ve eğitim-test performans sonuçları istatistiksel olarak sunulmuştur. Ayrıca önerilen hibrit modelin performansı literatürde iyi bilinen Levenberg-Marquardt algoritması ile eğitilen ileri beslemeli yapay sinir ağı (ANN) sonuçları ile de karşılaştırılarak yorumlanmıştır.

**Anahtar kelimeler:** Diferansiyel Gelişim Algoritması, ANFIS, Rüzgar Hızı Kestirimi, ANN.

---

## **Short-Term Wind Speed Forecasting Using Adaptive Neuro-Fuzzy Inference System Based on Differential Evolution Algorithm**

### **Abstract**

The electrical energy to be produced from wind energy systems should be estimated for some periods in order to generation planning and power systems management. In this context, many different wind speed forecasting approaches have been proposed for accurate estimation of asymmetric and unstable wind speed data. In this paper, short-term (1h) wind speed forecasting models have been developed by using Adaptive Neuro Fuzzy Inference System (ANFIS) based on Differential Evolution Algorithm (DE). In this paper, the model parameters have been determined by differential evolution heuristic approach for short-term wind speed forecasting and analyzed comparatively. To validate the effectiveness of the proposed approach, wind speed series collected from a wind observation station located in Bilecik, Turkey are used in the short-term wind speed forecasting. The meta-heuristic algorithm used in the optimization of ANFIS model parameters are run 10 times independently and the performance results are calculated statistically for training and test phases of ANFIS model. The performances of proposed hybrid models are also compared with the well-known feed forward ANN model which is trained by Levenberg-Marquardt in the literature.

**Keywords:** Differential Evolution Algorithm, ANFIS, Wind Speed Forecasting, ANN

---

---

\*Sorumlu yazar: [mehmet.kurban@bilecik.edu.tr](mailto:mehmet.kurban@bilecik.edu.tr)

Geliş Tarihi: 01.03.2019, Kabul Tarihi: 01.07.2019

## 1. Giriş

İklimdeki endişe verici değişiklikler ve artan nüfusa bağlı olarak, enerji üretim süreçlerinden kaynaklanan emisyonların çevre açısından değerlendirildiğinde giderek azaltılması talep edilmektedir. Yenilenebilir enerji kaynakları kullanılarak elektrik enerjisinin üretimi dikkate değer düzeyde bu emisyonların azaltılmasını bizlere sunmaktadır [1]. Günümüzde yenilenebilir enerji kaynaklarının en önemlilerinde biri olan rüzgar enerjisinin de kullanımı hızla artmaktadır. Global rüzgar enerjisi konseyi (GWEC) raporuna göre, dünyada 2017 yılında kurulan rüzgar enerji sistemlerinin kurulu gücü 52.492 MW iken global bazda toplam kümülatif kurulu güç değeri 539.123 MW'a ulaşmıştır. Kıtalar bazında 2017 sonu itibarıyla, Asya ve Avrupa kıtaları sırasıyla 228.684 MW, 177.506 MW değerleri ile en yüksek toplam kurulu güce sahiptir [2]. Ülkeler açısından Çin ve Amerika dünya genelinde yaklaşık olarak toplam kurulu gücün %52'sini oluşturmaktadır. Türkiye ise 2017 yılında yeni kurulan rüzgar enerji dönüştürme sistemleri açısından dünyada ilk 10 arasında yer almaktadır. 2018 ilk yarısında toplam kümülatif kurulum değeri Türkiye için 7.012,75 MW a ulaşmıştır. Türkiye'de Temmuz 2018 verilerine göre inşa halinde 885,27 MW'lık rüzgar enerji santrali yer almaktadır. Türkiye'nin ulusal hedefi 2023 yılı itibarıyla rüzgar gücü için 20 GW değerine ulaşmaktır [3].

Rüzgarın anlık değişim gösterebilen kesikli, asimetrik ve kaotik bir yapıya sahip olması rüzgar gücü tahminini güçleştirmekte ve enerji üretimi açısından öngörülebilirliğe engel olmaktadır. Rüzgar hızının ve buna bağlı olarak da rüzgar gücünün hassas bir şekilde tahmini; kurulması düşünülen rüzgar çiftliklerinin konumlarının belirlenmesi, verimli yönetimi, teknik servis talebi ve maliyeti, enerji birim maliyetlerinin önceden şekillendirilmesi, etkili ve verimli enerji piyasası, trafo merkezlerine aşırı yüklenme risklerinin en aza indirilmesi, rüzgar santrallerinin şebeke ile güvenli bağlantı kurabilmesi açısından da büyük öneme sahiptir [4].

Günümüzde, kısa dönemli rüzgar hızı tahminleri üzerine araştırmalar dikkat çekmektedir [5]. Literatürde, rüzgar hızı ve enerjisi tahmini için bir çok farklı yöntem kullanılmaktadır [6-10]. Bunlar, sayısal hava tahmin modelleri, istatistiksel yaklaşımlar ve hibrit metotlar olarak karşımıza çıkmaktadır. Sayısal hava tahminleri, sayısal prosedürler kullanılarak atmosferdeki hemen hemen tüm dinamik ve fiziksel süreçleri tanımlayan kapsamlı bir matematiksel denklemler dizisinin zaman-entegrasyonu yoluyla bir tahmin üretimi olarak tanımlanmaktadır [11]. Bu modeller, bir dizi iklimsel ve fiziksel giriş parametresi aracılığıyla rüzgardaki değişiklikleri tahmin edebilen akışkanlar mekaniğinin matematiksel modellerine dayanmaktadır [12]. Bu yöntemin en büyük dezavantajları arasında; sıcaklık, basınç ve nem gibi farklı ölçüm sistemlerine ihtiyaç duyması, işlem adım sürecinin uzun ve maliyetli oluşudur.

Literatürde rüzgar hızı tahmini üzerine yapılan çalışmalarda, istatistiksel yaklaşımlar zaman serisi analizleri üzerine olmakta iken, daha sonraki yıllarda hızla akıllı sezgisel yaklaşımlar üzerine yoğunlaşmakta ve son yıllarda hibrit modeller oldukça sık kullanılmaktadır [13-15]. Cadenas ve Rivera kısa dönem rüzgâr hızı tahmin analizlerini Meksika'da yer alan La Venta, Oaxaca bölgesinden alınan saatlik rüzgâr hızı verileri ile yapay sinir ağları kullanarak gerçekleştirmişlerdir [16]. Bu çalışmalarında 2 ve 3 katmanlı 3, 4, 6 ve 7 nöron sayısına sahip farklı yapay sinir ağı modelleri oluşturularak kısa dönemli tahminler yapılmıştır. Ocak ayına ait saatlik alınan 744 verinin 550 verisi eğitim, geri kalanı ise test verisi olarak seçilmiştir. Yapılan karşılaştırmalı analizlerde 2 katmanlı 3 nöronlu modelin diğer modellere göre daha iyi sonuç verdiği gözlemlenmiştir. Catalão ve arkadaşları, rüzgar gücü tahminini Portekiz verileri kullanarak kısa dönemli olarak gerçekleştirmişlerdir [17]. Önerilen yapay sinir ağı modeli sonuçlarına göre ortalama mutlak yüzdelik hata değerlerine bakıldığında % 7.26 hata oranı ile ortalama 5 sn'den kısa sürede hesaplanan rüzgâr gücü tahminini yapmışlardır. Moustris ve arkadaşları, güneş ve rüzgar enerji santrallerini bir arada bulunduran hibrit güç istasyonlarının optimum düzeyde çalıştırılması için yapay sinir ağlarını kullanarak 800kW'lık bir rüzgar türbinine sahip olan Yunanistan'ın Tilos adası için 24 saatlik kısa dönemli rüzgar hızı tahmini geliştirmişlerdir [18]. Yapay sinir ağının giriş verisinde geçmiş rüzgâr hızı verilerini kullandıkları gibi aynı zamanda hava basıncı değerinden de yararlanmışlardır. Sonuçlar ele alındığında, tahmin yöntemlerinin otomatik bir rüzgar gücü bilgi sistemini tasarlamak için yeterli sonuçlara ulaşıldığı görülmüştür. Türkiye'de yapılan çalışmalara bakıldığında; Akıncı, farklı yapay sinir ağı modelleri kullanarak Batman bölgesi için kısa dönemli rüzgar hızı tahmini gerçekleştirirken, Nogay ve arkadaşları benzer analizler kullanarak Mardin bölgesi için çalışmalarını yapmışlardır [19,20]. Bilgili ve arkadaşları yapay sinir ağlarını kullanarak Türkiye'deki Akdeniz bölgesinde bulunan 8 farklı ölçüm istasyonundaki verilerden yararlanarak rüzgar hızı tahmini üzerine çalışmalarda bulunmuşlardır. Eğitim algoritması olarak esnek yayılım kullanılmıştır.

Çalışmalarındaki hata performans kriterleri en çok %14,13 ile Antakya’da, en az hata ise %4,49 ile Mersin’de elde edilmiştir. Bu sonuçlar ANN modellerinin rüzgar hızı tahmininde başarılı sonuçlar ürettiğini göstermiştir [21].

Rüzgar hızı tahmini üzerine yapılan çalışmalarda farklı yöntemlerin birlikte kullanılarak daha hassas yaklaşımlar ile kestirimlerin hibrit bir yapıda gerçekleştiği görülebilir [22]. Gerek zaman serisi analizleri gerekse akıllı sezgisel yaklaşımlarda, farklı ayırıştırma metotları veya farklı optimizasyon teknikleri ile birlikte hibrit kullanımı daha hassas modellerin kurulabilmesi açısından önemlidir. Rüzgar hızı tahmini üzerine yapılan hibrit yaklaşımlarda, görgül kip ayrışımı, dalgacık dönüşümü gibi farklı ayırıştırma tekniklerini kullanarak orijinal işaretler ayırıştırılıp akıllı sezgisel yaklaşımlar ile bir arada kullanıldığı da görülmektedir [23]. Diğer hibrit yaklaşımlar ise farklı sezgisel metotlar kullanılarak optimize edilen yapay sinir ağları, uyarlamalı sinirsel bulanık çıkarım sistemi (ANFIS) veya çok katmanlı algılayıcı (MLP) sistemlerin parametrelerinin optimize edilerek yapılan tahmin işlemlerdir. Wang ve diğerleri, Diferansiyel gelişim algoritmasını birleştiren bir hibrit yük tahmin modeli önermekte ve bu problemi çözüm önerisi noktasında vektör regresyonunu desteklemektedir. Burada DE, destek vektör makineleri için yük tahmin modeli amacıyla uygun parametreleri seçmek için kullanılır. Bu modelin etkinliğini ise geri yayılım yapay sinir ağı kullanarak karşılaştırmışlar ve önerilen hibrit yaklaşımın yük tahmininde iyi sonuç verdiğini gözlemlemişlerdir [24].

Yapılan bu çalışmada, kısa dönem rüzgar hızı tahmini için hibrit ANFIS modeli önerilmiştir. ANFIS modelinin ağırlık ve kural parametrelerinin optimizasyonunda diferansiyel gelişim algoritması kullanılmıştır. Önerilen hibrit ANFIS yapısı ve yapay sinir ağları kullanılarak oluşturulan model ile de rüzgar hızı tahmini için karşılaştırmalı olarak analiz edilmiştir.

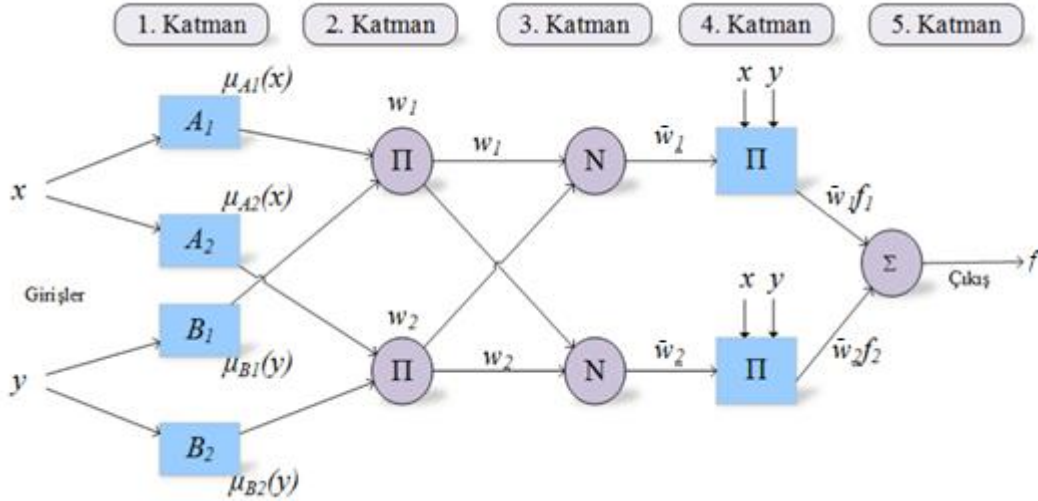
Bu çalışmada Bölüm 2 ve 3’de sırasıyla uyarlamalı bulanık çıkarım sistemi ve diferansiyel gelişim algoritması sunulmuş; Bölüm 4’ de ise diferansiyel gelişim algoritması ile optimize edilmiş ANFIS hibrit modeli uygulama sonuçları ile birlikte verilmiştir. Son bölümde ise sonuçlar ve gelecek çalışmalara ilişkin yorumlar ele alınmıştır.

## 2. Uyarlamalı Sinirsel Bulanık Çıkarım Sistemi

Uyarlamalı sinirsel bulanık çıkarım sistemi (ANFIS), yapısında hem bulanık mantığı hem de yapay sinir ağlarını barındıran Sugeno tipi bulanık sisteminin, sinirsel öğrenme kabiliyetine sahip bir ağ yapısını temsil etmektedir [25]. Bulanık sinir ağı olarak yapılan tanımlamada bulanık sistemin kombinasyonu olarak ifade edilmektedir. ANFIS yapısında uyarlamalı sistemlerden yararlanan bulanık Sugeno modeli öğrenme ve adaptasyon işlemlerini kolaylaştırmak için kullanılmaktadır. Böylece hibrit yaklaşım ile bulanık mantık daha sistematik ve tecrübeye daha az bağlı hale getirilmektedir [26]. Burada ki temel amaç, giriş-çıkış veri kümelerini kullanarak bir öğrenme algoritması vasıtasıyla eşdeğer bulanık mantık sisteminin parametrelerini optimize etmektir. Parametrelerin en iyilime durumu, hedefteki çıkış ile gerçek değer arasındaki hatanın minimize edilmesine dayanmaktadır [27].

Şekil 1’de birinci derece bulanık Sugeno modeli için olası ANFIS mimarisi iki bulanık kurala bağlı olarak verilmiştir

ANFIS modelinin katmanlarına baktığımızda, bulanıklaştırma işlemi giriş verilerine üyelik fonksiyonları uygulanarak 1. Katmanda yapılırken, bulanık mantık çıkarım sistemine göre 2. kurallar oluşturulur. Kural katmanından gelen her bir düğüme, ağırlıklı ortalama ile normalizasyon işlemi 3. katmanda uygulanır. Bulanık sonuçlar 4. katmanda nümerik değerlere dönüştürülür ve son adımda 5. katmanda tüm düğümlerin çıkış değerleri toplanarak sistemin tek çıkış değeri üretilir [28].



Şekil 1. 2 Giriş ve 1 çıkışlı ANFIS yapısı [29].

Tüm katmanlar aşağıdaki denklemlerle verilebilir:

$$\mu_{A_i}(x) = e^{\left(\frac{-(x-c_i)^2}{2\sigma_i^2}\right)}, i = 1,2 \quad (1)$$

$$\mu_{B_{i-2}}(y) = e^{\left(\frac{-(y-c_i)^2}{2\sigma_i^2}\right)}, i = 3,4 \quad (2)$$

$$w_i = \mu_{A_i}(x) \mu_{B_i}(y), i = 1,2 \quad (3)$$

$$\bar{w}_i = \frac{w_i}{\sum_i w_i}, i = 1,2 \quad (4)$$

$$f_i = p_i x + q_i y + r_i, i = 1,2 \quad (5)$$

$$\bar{w}_i f_i = \bar{w}_i (p_i x + q_i y + r_i), i = 1,2 \quad (6)$$

$$z = \sum_i \bar{w}_i f_i = \frac{\sum_i w_i f_i}{\sum_i w_i} \quad (7)$$

ANFIS'in ilk katmanında yer alan Eşitlik (1) ve (2)' de gösterilen,  $c_i$  ve  $\sigma_i$  önceden belirlenmiş geçmiş parametreleri ve  $\mu$  üyelik fonksiyonunu gösterir. İkinci katmandaki öncül kural sonuçları Eşitlik (3)' de gösterilmiştir. Ortalama öncül sonuçlar ( $\bar{w}_i$ ) üçüncü katmanın çıkışında hesaplanır. Eşitlik (5)'deki  $p_i, q_i, r_i$  sonuç parametrelerini gösterirken,  $f_i$  Sugeno tip bulanık sistemin kurallarını göstermektedir. Uygulama ve kural sonuçlarının değerlendirilmesi, son katmanın çıktısında sunulmuştur.

### 3. Diferansiyel Gelişim Algoritması

Diferansiyel gelişim algoritması (DE) popülasyon temelli sezgisel bir optimizasyon tekniği olup, Rainer Storn ve Kenneth Price tarafından ortaya atılan Chebyshev polinomsal uyum problemini çözme amacı ile geliştirilmiş bir optimizasyon tekniğidir [30-31]. Genetik algoritmalarda kullanılan çaprazlama, karşılaştırma ve mutasyon işlemleri ayrı ayrı gerçekleştirilir. Bu sebeple genetik algoritmalarda optimizasyon için uzun zamana ihtiyaç duyulurken DE'de ise her bir operatör tüm popülasyona sırayla uygulanır, böylece DE'de gelişime dayalı bir strateji önerilerek problemin çözümüne daha kısa sürede ulaşılır. Algoritmada öncelikle en iyi kromozomlar başlangıç popülasyonunda seçilerek çaprazlama ve mutasyon operatörleri kullanılarak yeni bir birey elde edilir. Mevcut kromozomlar arasındaki en iyi olan birey seçim operatörü de kullanılarak bir sonraki popülasyona aktarılmaktadır. Bu şekilde tüm popülasyon, istenilen iterasyon sayısı veya hata değeri sağlanıncaya kadar mutasyon, çaprazlama ve karşılaştırma işlemlerine tabi tutulur. Bu işlemin amacı problemin tüm koşullarını sağlayan en iyi çözüme ulaşmaktır.

DE'nin kaba kodu aşağıda verilmiştir.

Başlangıç Fazı;

WHILE

DO Maksimum İterasyon Sayısı;

Rekombinasyon Fazı (mutasyon & çaprazlama);

Değerlendirme Fazı (yeni değerleri hesaplama);


Seçim Fazı (en iyi adayı seçimi);

Şimdiye kadar elde edilen en iyi değeri sakla;

ENDWHILE;


#### 4. ANFIS-DE Modeli Kullanılarak Kısa Dönemli Rüzgar Hızı Kestirimi

Çalışmamız kapsamında Bilecik ili gözlem istasyonundan alınan saatlik rüzgar hızı değerleri çalışmamızın veri kümesini oluşturmuştur. Bu kapsamda yapılan aylık analizde veri seti içerisinde rüzgar hızı değerlerinin bir önceki zaman, şimdiki zaman değerlerini içeren, giriş ve bir sonraki zaman dilimi ile oluşturulan çıkış yapısının toplam rüzgar hızı verisi içerisindeki %70'lik kısmı eğitim, geriye kalan %30'luk rüzgar hızı verisi ise aynı geçmiş veri tekniği referans alınarak test aşamasında kullanılmıştır. Şekil 2'de örnek bir aya ait zamana bağlı rüzgar hızı verileri yer almaktadır.




Şekil 2. Rüzgar hızı verileri

Analizlerde kullanılmak üzere seçilen ANFIS modeli Şekil 3'de gösterilmiştir. 2 giriş bir çıkışlı sistem için model oluşturulmuştur. Seçilen ANFIS model parametreleri sezgisel yaklaşımlar arasında yer alan diferansiyel gelişim algoritması ile belirlenerek kısa dönemli rüzgar hızı tahmini için hibrit bir yapı önerilmektedir.



Şekil 3. Analizde kullanılan ANFIS modeli

Şekil 4’de de görüleceği üzere eğitim ve test verilerinin seçim prosedüründe geçmiş ve gelecek veriler arasında bir adımlı kısa dönemli rüzgar hızı tahmin modeli geliştirilmiştir. Bu kapsamda iki geçmiş zaman öncesine kadarki veriler bir sonraki zaman dilimiyle ilişkilendirilmiştir.



Şekil 4. Eğitim ve test verilerinin seçim prosedürü

Önerilen ANFIS-DE hibrit modeli Eşitlik 8-11’de verilen hataların karelerinin ortalamasının karekökü (RMSE), ortalama karesel hata (MSE), ortalama mutlak hata (MAE) ve ortalama mutlak hata yüzdesi (MAPE) performans kriterlerine göre ANN sonuçları ile karşılaştırmalı olarak analiz edilmiştir.

$$\text{RMSE} = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (8)$$

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (9)$$

$$\text{MAE} = \frac{1}{N} \sum_{i=1}^N |y_i - \hat{y}_i| \quad (10)$$

$$\text{MAPE} = \frac{1}{N} \sum_{i=1}^N \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (11)$$


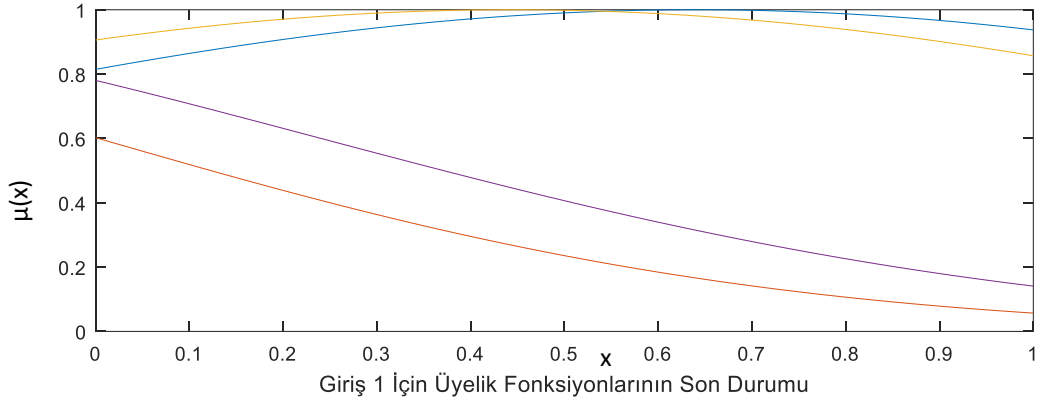
Hibrit ANFIS model kodu, Intel® (Intel Core) TM (i5-3230M CPU@2.60GHz/8.00GB RAM) olan bilgisayarda çalıştırılmıştır. Önerilen hibrit model için 10 tekrarlı analizlerde elde edilen hata performans kriterlerinin en yüksek, en düşük, ortalama değerleri ile standart sapma sonuçlarının istatistiksel bilgileri Tablo 1’de gösterilmiştir.

**Tablo 1.** Tekrarlı analizlerde ANFIS-DE ve ANN test ve eğitim sonuçları


		Eğitim Sonuçları				Test Sonuçları			
		MSE	RMSE	MAE	MAPE	MSE	RMSE	MAE	MAPE
ANFIS-DE	en iyi	8.97e-03	9.47e-02	7.20e-02	%26.13	8.44e-03	9.19e-02	7.13e-02	%27.74
	en kötü	9.06e-03	9.52e-02	7.31e-02	%30.32	8.70e-03	9.33e-02	7.29e-02	%32.47
	ort.	9.01e-03	9.49e-02	7.26e-02	%27.58	8.60e-03	9.27e-02	7.22e-02	%29.22
	std.	3.22e-05	1.69e-04	3.40e-04	%1.28	1.08e-04	5.81e-04	5.55e-04	%1.46
ANN	en iyi	8.59e-03	9.27e-02	7.05e-02	%25.85	8.18e-03	9.04e-02	6.94e-02	%28.12
	en kötü	1.00e-02	1.00e-01	7.66e-02	%30.15	9.32e-03	9.65e-02	7.24e-02	%31.39
	ort.	8.95e-03	9.46e-02	7.21e-02	%27.34	8.58e-03	9.26e-02	7.11e-02	%29.42
	std.	4.43e-04	2.30e-03	1.84e-03	%1.28	3.27e-04	1.75e-03	9.96e-04	%1.19

Tablo 1’den de görülebileceği üzere ANN ve ANFIS-DE performans verilerine bakıldığında, eğitim ve test verilerinde her iki modelinde birbirlerine alternatif olarak kullanılabilenliği söylenebilir. Bu kapsamda eğitim ve test sonuçlarına göre 10 tekrarlı analizlerde birbirlerine yakın hata oranlarının yer aldığı gözlemlenmektedir.

Şekil 5’de eğitim sonunda elde edilen üyelik fonksiyonu gösterilmiştir. Aynı zamanda hibrit modelin en iyi ve en kötü eğitim sonundaki yakınsama değerleri Şekil 6’da ele alınmıştır.



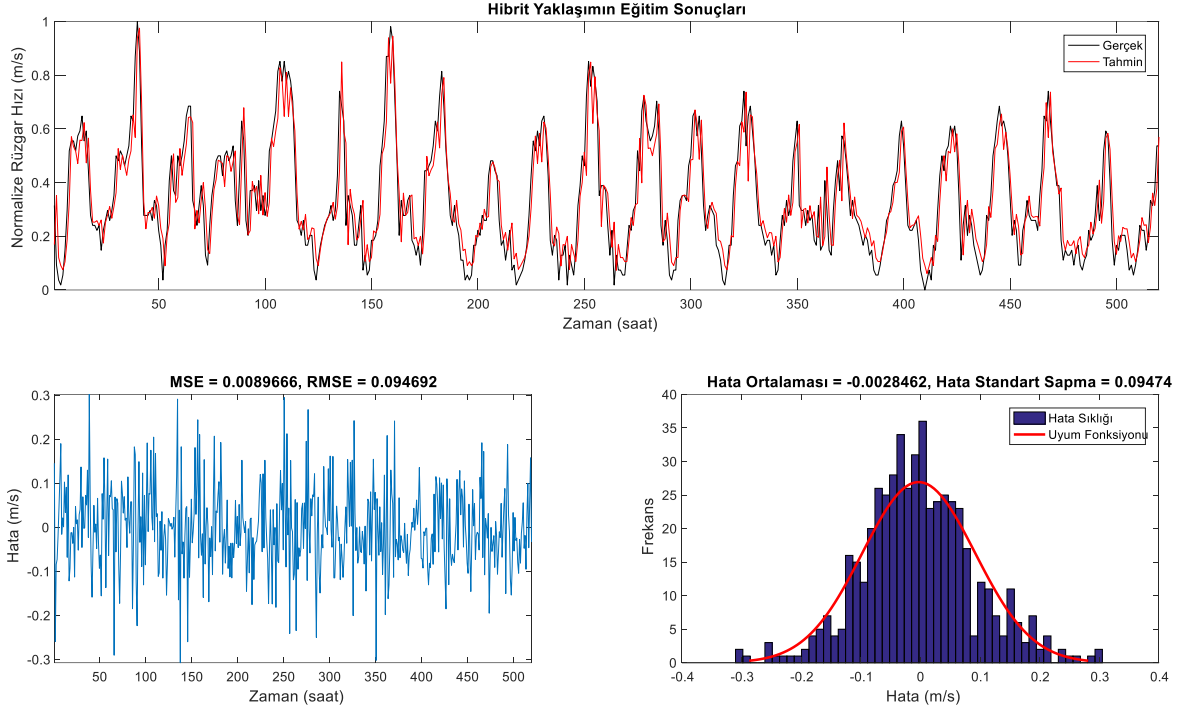
Şekil 5. En iyi ANFIS-DE eğitimi sonunda elde edilen üyelik fonksiyonları



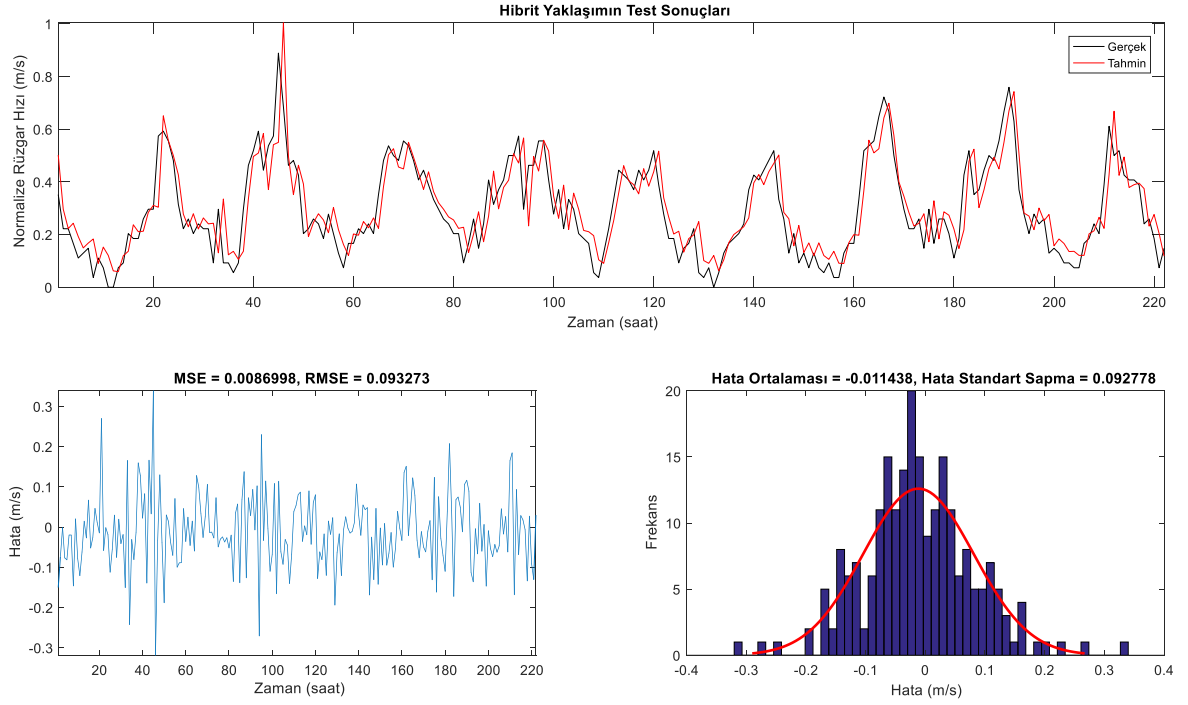
Şekil 6. En iyi ve en kötü ANFIS-DE eğitimi sonunda elde edilen yakınsama eğrileri

ANFIS-DE hibrit yaklaşımının eğitim ve test sonuçları ile hata performans analizleri kısa dönemli rüzgar hızı tahmini için Şekil 7’de gösterilmektedir. Şekil 8’den de görülebileceği üzere rüzgar hızı verilerinin ani değişim gösterdiği aşım noktalarında tahmin performansının düştüğü görülebilir.






Şekil 7. Kısa dönem rüzgar hızı kestirimi için en iyi ANFIS-DE eğitim sonuçları



Şekil 8. Kısa dönem rüzgar hızı kestirimi için en iyi ANFIS-DE test sonuçları

Önerilen hibrit yaklaşım ve ANN test sonuçlarının karşılaştırmalı analiz sonuçları ise Şekil 9'da gösterilmektedir.



Şekil 9. Kısa Dönem Rüzgâr Hızı Kestirimi için Test Sonuçları

Şekil 9'dan görülebileceği üzere, ANN'in en büyük performans avantajı rüzgâr hızı verilerinin ani değişim gösterdiği aşım noktasını ANFIS-DE'ye göre daha iyi yakalayabilmesi olmuştur. Fakat genel olarak RMSE, MSE, MAE ve MAPE performans kriterleri göz önüne alındığında bu aşım noktası dışında her iki modelde birbirlerine alternatif olarak kullanılabilirliği öngörülebilmektedir.

#### 4. Sonuç ve Öneriler

Günümüzde artan enerji ihtiyacına paralel olarak rüzgâr enerjisi dönüştürme sistemlerinin şebekeye entegrasyonunda rüzgâr hızı tahmini büyük öneme sahiptir. Rüzgârın anlık değişim gösterebilen kesikli, asimetrik ve kaotik bir yapıya sahip olması rüzgâr gücü tahminini güçlendirmekte ve enerji üretimi açısından öngörülebilirliğe engel olmaktadır. Bu çalışmada diferansiyel gelişim algoritması (DE) ile optimize edilen ANFIS parametreleri kullanılarak hibrit model, kısa dönemli rüzgâr hızı tahmini için önerilmektedir. Rüzgâr hızı veri setinin iki giriş ve bir çıkışlı durumu için ANFIS-DE hibrit yaklaşımının hata performans analizleri gerçekleştirilmiştir. Gerçekleştirilen analizlerde 10 tekrarlı hata performans sonuçlarının en iyi, en kötü, ortalama ve standart sapma değerleri sunulmuştur. Bu kapsamda önerilen hibrit yaklaşımın RMSE, MSE ve MAE test performans kriterlerine bakıldığında değerleri sırasıyla  $8.60e-03$ ,  $9.27e-02$ ,  $7.22e-02$  olarak gözlemlenmiştir. Ayrıca çalışmada iki girişli bir çıkışlı durum içinde yapay sinir ağları ile analizler gerçekleştirilmiş ve hibrit modellerle karşılaştırılmıştır. Elde edilen karşılaştırma sonuçlarına göre her iki modelinde birbirlerine alternatif olarak kullanılabilirliği öngörülmektedir. Gelecekteki çalışmalarda, farklı giriş ve çıkış sayılarına göre ve aynı zamanda birden fazla adımlı durumlar için analizlerin yapılabilmesi hata performans kriterlerinin azalmasında rol oynayacağı düşünülmektedir.

## Kaynaklar

- [1] Dinçer F., Rüstemli S., Yılmaz Ş., Çıngı A. 2017. Kilis İli İçin Farklı Yüksekliklerdeki Rüzgâr Potansiyelinin Belirlenmesi. Bitlis Eren Üniversitesi Fen Bilimleri Dergisi, 6 (1): 12-20.
- [2] GWEC. 2017. Global Wind Report Annual Market Update, Global Wind Energy Council.
- [3] Turkish Wind Energy Association, Turkish Wind Energy Statistics Report, 2018.
- [4] Redlinger R., Andersen P., Morthorst P. 2016. Wind Energy in the 21st Century: Economics, Policy, Technology and the Changing Electricity Industry, Springer.
- [5] Deo R.C., Ghorbani M.A., Samadianfard S., Maraseni T., Bilgili M., Biazar M. 2018. Multi-layer perceptron hybrid model integrated with the firefly optimizer algorithm for wind speed prediction of target site using a limited set of neighboring reference station data. Renewable Energy, 116 (2018): 309-323.
- [6] Su Z., Wang J., Lu H., Zhao G. 2014. A new hybrid model optimized by an intelligent optimization algorithm for wind speed forecasting. Energy Conversion and Management, 85 (2014): 443-452.
- [7] Liu H., Chen C., Tian H.Q., Li Y.F. 2012. A hybrid model for wind speed prediction using empirical mode decomposition and artificial neural networks. Renewable Energy, 48 (2012): 545-556.
- [8] Liu H., Tian H.Q., Pan D.F., Li Y.F. 2013. Forecasting models for wind speed using wavelet, wavelet packet, time series and Artificial Neural Networks. Applied Energy, 107 (2013): 191-208.
- [9] Guo Z., Chi D., Wu J., Zhang W. 2014. A new wind speed forecasting strategy based on the chaotic time series modelling technique and the Apriori algorithm. Energy Conversion and Management 84 (2014): 140-151.
- [10] Zhang C., Wei H., Zhao X., Liu T., Zhang K. 2016. A Gaussian process regression based hybrid approach for short-term wind speed prediction. Energy Conversion and Management, 126 (2016): 1084-1092.
- [11] Hu J., Wang J., Ma K. 2015. A hybrid technique for short-term wind speed prediction. Energy, 81 (2015): 563-574.
- [12] Hu J., Wang J., Zeng G. 2013. A hybrid forecasting approach applied to wind speed time series. Renewable Energy, 60 (2013): 185-194.
- [13] Rahmani R., Yusof R., Seyedmahmoudian M., Mekhilef S. 2013. Hybrid technique of ant colony and particle swarm optimization for short-term wind energy forecasting., Journal of Wind Engineering and Industrial Aerodynamics 123 (2013): 163-170.
- [14] Kassa Y., Zhang J.H., Zheng D.H., Wei D. 2016. A GA-BP hybrid algorithm based ANN model for wind power prediction. Smart Energy Grid Engineering (SEGE) IEEE, 2016.
- [15] Pousinho H.M.I., Catalao J.P.S., Mendes V.M.F. 2010. Wind power short-term prediction by a hybrid PSO-ANFIS approach. MELECON 2010, 15th IEEE Mediterranean Electrotechnical Conference. IEEE, 2010.
- [16] Cadenas E., Rivera W. 2009. Short-term wind speed forecasting in La Venta, Oaxaca, México, using artificial neural networks, Renewable Energy, 34 (1): 274-278.
- [17] Catalão J.P.S., Pousinho H.M.I., Mendes V.M.F. 2009. An artificial neural network approach for short-term wind power forecasting in Portugal. Intelligent System Applications to Power Systems, ISAP'09. 15th International Conference on. IEEE, 2009.
- [18] Moustris K.P., Zafirakis D., Alamo D.H., Medina R.N., Kaldellis J.K. 2017. 24-h ahead wind speed prediction for the optimum operation of hybrid power stations with the use of artificial neural networks. Perspectives on Atmospheric Sciences, Springer, Cham, 409-414.
- [19] Akinci T.C. 2011. Short-term wind speed forecasting with ANN in Batman, Turkey. Elektronika ir Elektrotechnika, 107 (1): 41-45.
- [20] Nogay S.H., Akinci T.C., Eidukeviciute M. 2012. Application of artificial neural networks for short-term wind speed forecasting in Mardin, Turkey, Journal of Energy in Southern Africa 23 (4): 2-7.
- [21] Bilgili M., Sahin B., Yasar A. 2007. Application of artificial neural networks for the wind speed prediction of target station using reference stations data. Renewable Energy, 32 (14): 2350-2360.

- [22] Dokur E., Kurban M., Ceyhan S. 2015. Hybrid model for short-term wind speed forecasting using empirical mode decomposition and artificial neural network. Electrical and Electronics Engineering (ELECO), 2015 9th International Conference on. IEEE, 2015.
- [23] Liu H., Tian H., Li Y. 2015. Comparison of new hybrid FEEMD-MLP, FEEMD-ANFIS, Wavelet Packet-MLP and Wavelet Packet-ANFIS for wind speed predictions. Energy Conversion and Management 89: 1-11.
- [24] Wang J., Li L., Niu D., Tan Z. 2012. An annual load forecasting model based on support vector regression with differential evolution algorithm. Applied Energy, 94: 65-70.
- [25] Avcı E., Akpolat Z. H. 2002. Uyarlamalı ağ tabanlı bulanık çıkarım sistemi ile doğru akım motorlarının hız denetimi. Pp: 193-196. ELECO'2002 ElektrikElektronik-Bilgisayar Mühendisliği Sempozyumu, Aralık, 2002, Bursa.
- [26] Özgan E., Kap T., Beycioğlu A., Emiroğlu M. 2009. Asfalt betonunda Marshall stabilitesinin uyarlamalı sinirsel bulanık mantık yaklaşımı ile tahmini. Uluslararası İleri Teknolojiler Sempozyumu, Karabük.
- [27] Güney K., Sarıkaya, N., 2008. Dairesel mikroşerit antenlerin yama yarıçapının çeşitli algoritmalarla optimize edilen bulanık mantık sistemine dayalı uyarlanırlar ağlar ile hesaplanması. ELECO'2008 Elektrik-Elektronik-Bilgisayar Mühendisliği Sempozyumu ve Fuarı, 26-30 Kasım, 2008, Bursa.
- [28] Haznedar B., Kalinli A. 2016. Training ANFIS using genetic algorithm for dynamic systems identification, pp. 22-26. International Conference on Advanced Technology & Sciences (ICAT'16), 1-3 Eylül, 2016, Konya, Turkey.
- [29] Haznedar B. 2017. Benzetilmiş Tavlama Algoritması İle Adaptif Ağ Tabanlı Bulanık Mantık Çıkarım Sisteminin (Anfis) Eğitilmesi. Doktora Tezi, Erciyes Üniversitesi, Fen Bilimleri Enstitüsü, 174s, Kayseri.
- [30] Storn R. 1997. Differential Evolution-A Simple and Efficient Heuristic Strategy for Global Optimization Over Continuous Spaces. Journal of Global Optimization, 11: 341-359.
- [31] Yılmaz A.R. 2014. FPGA Üzerinde Diferansiyel Gelişim Algoritması İle Yapay Sinir Ağı Eğitimi. Yüksek Lisans Tezi, YTÜ, Fen Bilimleri Enstitüsü, 77s, İstanbul.