

GAUSS FONKSİYONLARI İLE PENCERELENMİŞ POLİNOM AKTİVASYON FONKSİYONU KULLANAN DALGACIK SİNİR AĞI İLE YAPAY SİNİR AĞLARININ, ÇOK KISA VADELİ RÜZGAR HIZI TAHMİNİNDE, TAHMİN BAŞARIMLARININ KARŞILAŞTIRILMASI

Serkan Şenkal^{1*}, Cem Emeksiz²

¹Mekatronik Mühendisliği, Tokat Gaziosmanpaşa Üniversitesi, Tokat, Türkiye

²Elektrik Elektronik Mühendisliği, Tokat Gaziosmanpaşa Üniversitesi, Tokat, Türkiye

*Sorumlu Yazar: serkan.senkal@gop.edu.tr

+Sunucu: serkan.senkal@gop.edu.tr

Presentation/Paper Type: Oral / Full Paper

Özet – Fosil bazlı yakıtların giderek ömrünü tamamladığı dünyamızda alternatif enerji kaynaklarının önemi hızla artmaktadır. Bir alternatif enerji şekli olan rüzgar enerjisinde, rüzgar türbinleri kurulu olduğu alanın sadece %1'ini işgal etmesi ve kurulduğu kırsal alanlarda tarım, hayvancılık ve ormancılık gibi faaliyetlere engel olmadığı için güneş enerji santrallerine göre daha fazla tercih edilebilir konumdadır. Ancak rüzgar enerjisinin değişkenliği ve süreksizliği, elektrik şebekesi içine rüzgar enerjisini entegre etmenin en büyük zorluğudur. Bu durumun önüne geçebilmenin en akıllıca yolu, rüzgar enerjisi üretiminin gelecekteki değerlerini tahmin etmektir. Yüksek doğrulukları ile rüzgar hızı tahmin yöntemleri bu sorunları en aza indirmek için kullanılabilecek etkili bir araçtır.

Bu çalışma, geleneksel fonksiyonlu Yapay Sinir Ağları (YSA) ve Gauss Fonksiyonları ile Pencerelemiş Polinom fonksiyonlarından POLYWOG1 aktivasyon fonksiyonu kullanan Dalgacık Sinir Ağları (DSA) kullanılarak çok kısa süreli rüzgar hızı tahminini ve bu ağların başarımlarının karşılaştırmasını sunmaktadır. Veri, bir yıllık bir süre için on dakikalık çözünürlükte Ondokuz Mayıs Üniversitesi'nde bulunan bir hava istasyonundan toplanmıştır. Rüzgar hızı tahminler önümüzdeki 10 dakika için 24 saatlik bir süre içinde sunulmaktadır. YSA ve DSA için aynı topoloji kullanılmasına rağmen, DSA için önerilen tahmin sisteminin başarımları, YSA'ya göre daha yüksektir. Kök Hata Kareler Ortalaması (RMSE) ve Ortalama Karesel Hata (MSE) başarımlarını olarak seçilmiştir.

Rüzgar enerjisi sağlayan sistemlerin, elde edilecek tahminler doğrultusunda, değişen atmosferik şartlara doğru ve hızlı şekilde uyumluğunun sağlanması hedeflenmektedir.

Anahtar Kelimeler – Dalgacık Sinir Ağı, Yapay Sinir Ağı, Rüzgar Hızı Tahmini

I. GİRİŞ

Rüzgar, yenilebilir bir enerji kaynağı olması, genel olarak basit bir yapıda olması ve elde edilen verimin yüksek olması, diğer santrallere göre çok kısa bir sürede kurulabilmesi nedenleriyle elektrik enerjisi üretiminde kullanımı sürekli olarak artan bir enerji kaynağıdır. Ancak, rüzgar santrallerinin diğer konvansiyonel santrallerden farklı yapıda olması nedeniyle buldukları bölgelerde elektrik şebekesine bağlantıları sırasında güç kalitesi yönünden bazı sorunlar meydana gelmektedir. Bu sorunları giderebilmek adına yapılan çalışmalar göstermektedir ki; doğruluk oranı yüksek rüzgar tahminlerinin yapılması, uygun ve teknik kapasitesi yüksek jeneratör seçimi, gerilim dalgalanmalarının en aza indirilmesi, harmonik ve flikerin belirlenen sınır değerler içinde tutulması, rüzgar türbininin arıza ve arıza sonrası tepkilerinin ilgili kriterlere uyması, aktif ve reaktif gücün kontrolünün yapılması güç kalitesini artıran en önemli faktörlerdir [1].

Rüzgar tahmin metodlarının zaman bazında sınıflandırılması kesinlik arz etmemektedir. Bununla beraber rüzgar tahmini dört kategoride incelenebilir;

- Çok kısa vadeli tahminler; birkaç saniyeden 30 dakikaya kadar,
- Kısa vadeli tahminler; 30 dakikadan 6 saate kadar,
- Orta vadeli tahminler; 6 saatten 1 güne kadar,
- Uzun vadeli tahminler; 1 günden 1 haftaya kadar (ve daha fazlası) [2].

II. MATERYAL VE METOT

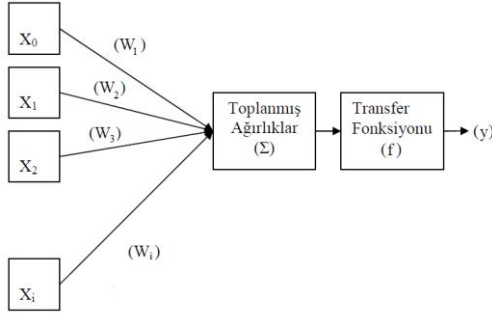
A. Yapay Sinir Ağı (YSA)

Yapay sinir ağları (YSA), insan beyni esas alınarak modellenmiş bir sistemdir. Klasik yöntemlerle çözülemeyen problemleri insan beyninin çalışma sistemine benzer yöntemlerle çözmeye çalışır [3]. Bilgisayar ortamında, beynin yaptığı işlemleri yapabilen, karar veren, sonuç çıkaran, yetersiz veri durumunda var olan mevcut bilgiden yola çıkarak sonuca ulaşan, sürekli veri girişini kabul eden, öğrenen,

hatırlayan bir algoritma kısaca “Yapay Sinir Ağları” olarak adlandırılır [3,4].

YSA uygulamalarında tek katmanlı ve çok katmanlı sinir ağları kullanılır. Tek katmanlı ağ, bir girdi ve bir çıktı katmanından oluşur. Burada girdi katmanı işlem yapmaz. Basit olarak ağırlıklarla değiştirilen girdileri, gelecek katmandaki her bir sinire gönderir [5].

Biyolojik sinir hücresinin girdi, işlem ve çıktı karakteristiğini gerçekleştirmek üzere oluşturulmuş bir yapay sinir hücresi Şekil 1 ile verilmiştir. Bunlar: girişler (X_i), ağırlıklar (W_i), toplam fonksiyonları (Σ), aktivasyon (transfer) fonksiyonu (f) ve çıkış değeri (y)’dir.



Şekil 1. Yapay sinir hücresi.

Bu hücrelerin paralel bağlanması ile katmanlar, katmanların da seri bağlanması ile çok katmanlı yapay sinir ağları oluşur. Genelde bir giriş katmanı, bir gizli katman ve bir de çıkış katmanından oluşan ağlar kullanılmaktadır [6].

Yapay sinir ağları iki aşamalı olarak çalışmaktadır:

- Öğrenme aşaması,
- Test aşaması.

Öğrenme aşamasında ağın giriş-çıkış ilişkisini veren matematiksel bağıntıdaki ağırlık katsayıları (ω) ve eşik katsayıları (b) ayarlanır. Ağırlık vektörü ω , $\omega(0)$ başlangıç değerinden başlanarak ardışıl olarak değiştirilir. ($k+1$) adım için ω ağırlık vektörü şu şekilde hesaplanır:

$$\omega(k+1) = \omega(k) + \Delta\omega(k)$$

$\Delta\omega$, ağırlık değişimi, x giriş vektörü ile öğrenme işareti r 'nin çarpımı ile orantılıdır. Öğrenme işareti r , genel olarak ω , x ve hedeflenen çıkış t 'nin bir fonksiyonudur. Buna göre k . adım için $\Delta\omega(k)$ şu şekilde yazılabilir:

$$\Delta\omega(k) = \alpha r [\omega(k), x(k), t_j(k)]$$

Burada α , öğrenme oranı olarak adlandırılan ve öğrenmenin hızını belirleyen pozitif bir sayıdır.

Test aşamasında, Eğitim aşamasında bulunan ω ve b değerleri kullanılarak elde edilen matematiksel model yardımı ile giriş verilerine karşılık düşen çıkış değerleri bulunur.


Yapay sinir ağları, giriş verisi ile çıkış rüzgar hızları arasındaki ilişkiyi öğrenebilmesi için uzun bir zaman çerçevesinde alınan geçmiş veriler kullanılarak eğitilirler. Yapay sinir ağları, öğrenme için geçmiş veriler ile beslenen bir giriş katmanı, saklı katman/katmanlar ve tahmin sonuçlarını sağlayan çıkış katmanından oluşur. YSA modelleri; ileri beslemeli sinir ağları, çok katmanlı algılayıcılar, tekrarlamalı sinir ağları, radyal tabanlı fonksiyon sinir ağları, ADALINE ağları gibi modeller olabilir.

B. Dalgacık Sinir Ağı (DSA)

Dalgacık sinir ağları (DSA), dalgacık teorisi ile sinir ağı teorisini bir araya getirmiştir. Bir dalgacık sinir ağı, aktivasyon fonksiyonu orthonormal dalgacık ailesinden seçilmiş, tek gizli katmanlı bir ileri beslemeli sinir ağından oluşur [7].

Dalgacık sinir ağlarının bir uygulaması da bu orthonormal fonksiyonun tahmin edilmesidir. Bir fonksiyonun bir dizi gözlenen değeri verildiğinde, dalgacık ağı o fonksiyonun yapısını öğrenebilecek şekilde eğitilebilir ve verilen rastgele girişler için beklenen değerleri hesaplayabilir [7].

Dalgacık sinir ağı yapı olarak $(1 + \frac{1}{2})$ katman sinir ağına çok benzer. Bu yapı; bir veya daha fazla girişi olan, tek gizli katmanlı, ileri beslemeli bir ağıdır ve çıkış katı, bir veya daha çok doğrusal birleştirici ya da toplayıcı içerir. Gizli katmanda bulunan nöronların aktivasyon fonksiyonları dalgacık tabanlıdır. Bu dalgacık nöronları genellikle “wavelon” olarak isimlendirilir [7].



Şekil 2. Dalgacık sinir ağı yapısı.


1. Tek boyutlu dalgacık sinir ağı

Dalgacık sinir ağının en basit formu tektir ve bir giriş ile bir çıkıştan oluşur. Gizli katmanda, giriş parametreleri (muhtemelen sabittir) dalgacığın öteleme ve genişleme katsayılarını içeren dalgacık nöronları bulunur. Bu dalgacık nöronları; girişler, giriş kümesinin küçük bir alanı içinde kaldığında, sıfırdan farklı bir çıkış üretir. Dalgacık sinir ağının çıkışı, dalgacık aktivasyon fonksiyonlarının ağırlıklı doğrusal bileşimidir.

Şekil 3'te tek çıkışlı dalgacık nöronun yapısı gösterilmektedir. Çıkış;

$$\psi_{\lambda,t}(u) = \psi\left(\frac{u-t}{\lambda}\right)$$

Şeklinde ifade edilir. λ ve t sırasıyla öteleme ve genişleme parametreleridir.



Şekil 3. Dalgacık nöronu.


Tek giriş tek çıkış dalgacık ağı mimarisi Şekil 4'te gösterilmiştir. Gizli katman M adet dalgacık nöronu içerir. Çıkış nöronu bir toplayıcıdır ve dalgacık nöronlarının çıkışlarının ağırlıklı toplamını çıkış olarak verir.

$$y(u) = \sum_{i=1}^M w_i \psi_{\lambda_i, t_i}(u) + \bar{y}$$

\bar{y} değerinin eklenmesinin sebebi, dalgacık fonksiyonu $\psi(u)$ sıfır ortalamalı olduğu sürece, ortalaması sıfırdan farklı fonksiyonlarla başa çıkmak içindir. \bar{y} , ölçekleme fonksiyonu için bir yer değiştirme değeridir.

Bir dalgacık ağı ait tüm parametreler bazı öğrenme algoritmaları ile ayarlanabilir [7].

Wavenet mimarisi dalgacık ağı ile aynıdır fakat t_i ve λ_i parametreleri başlangıçta sabittir ve herhangi bir öğrenme prosedürü ile değişmez [7].



Şekil 4. Dalgacık sinir ağı.

Bu kısıtlamanın ana sebeplerinden biri dalgacık analizinden gelmektedir. Yani, aşağıda verilen herhangi bir $f(\cdot)$ fonksiyonu için yeterince büyük bir L değeri seçilerek keyfi bir ayrıntı seviyesine yaklaştırılabilir.

$$f(u) \approx \sum_k \langle f, \varphi_{L,k} \rangle \varphi_{L,k}(u)$$

burada $\varphi_{L,k}(u) = 2^{L/2} \varphi(2^L u - k)$ ölçekleme fonksiyonu 2^L ile genişletilmiş ve 2^{-L} ikili aralığı ile ötelenmiştir. Bu nedenle wavenet'in çıkışı;

$$y(u) = \sum_{i=1}^M w_i \varphi_{\lambda_i, t_i}(u)$$

şeklinde olacaktır. Burada M , analiz edilecek fonksiyonun kümesini kapsayacak derecede büyük olmalıdır. Şunu da eklemek gerekir ki, ölçekleme fonksiyonunun ortalaması sıfırdan farklı olduğu sürece düzeltme değeri olan \bar{y} değerine ihtiyaç olmayacaktır [7].


2. Çok boyutlu dalgacık sinir ağı

Bu tip dalgacık sinir ağında, giriş çok boyutlu bir vektördür ve dalgacık nöronları çok boyutlu aktivasyon fonksiyonları içermektedir. Giriş vektörü, çok boyutlu giriş uzayının küçük bir alanında kaldığı sürece, dalgacık nöronları sıfırdan farklı bir çıkış üretir. Dalgacık sinir ağının çıkışı, bu çok boyutlu dalgacıkların bir tanesinin veya daha fazlasının doğrusal bileşiminden oluşur [7].

Şekil 5'te çok boyutlu dalgacık sinir ağı için dalgacık nöronun yapısı gösterilmiştir. Çıkışı;

$$\psi(u_1, \dots, u_N) = \prod_{n=1}^N \psi_{\lambda_n, t_n}(u_n)$$

şeklinde ifade edilir. Bu dalgacık nöronun etkisi, çok boyutlu bir dalgacığa eşdeğerdir.



Şekil 5. Çok boyutlu dalgacık aktivasyon fonksiyonlu dalgacık nöronu.

Çok boyutlu dalgacık sinir ağının mimarisi Şekil 2'de gösterilmiştir. Gizli katman M adet dalgacık nöronu, çıkış katmanı ise K adet toplayıcı içerir. Ağın çıkışı aşağıdaki gibi ifade edilir.

$$y_j = \sum_{i=1}^M w_{ij} \psi_i(u_1, \dots, u_N) + \bar{y}_j \quad (j = 1, \dots, K)$$

Burada, \bar{y}_j değerine, ortalaması sınırdan farklı fonksiyonlarla başa çıkabilmek için ihtiyaç duyulmaktadır. Dolayısıyla, ağın giriş - çıkış ifadesi aşağıdaki gibi tanımlanabilir;

$$y(u) = \sum_{i=1}^M w_i \psi_i(u) + \bar{y}$$

burada $\begin{cases} y = (y_1, \dots, y_K) \\ w_i = (w_{i1}, \dots, w_{iK}) \\ u = (u_1, \dots, u_N) \\ \bar{y} = (\bar{y}_1, \dots, \bar{y}_K) \end{cases}$

C. Sinir Ağı Mimarisinin Belirlenmesi

Ondokuz Mayıs Üniversitesi, Kurupelit yerleşkesine konuşlandırılan ölçüm istasyonundan alınan 10 dakika aralıklı sıcaklık, nem, basınç ve 40 m yükseklikteki hız verileri kullanılarak öncelikli olarak çok kısa vadeli rüzgar hızı tahmini yapılmaya çalışılmıştır. Ayrıca kullanılan yöntemin kısa, orta ve uzun vadeli tahmin dönemleri için başarımının test edilmesi de ihmal edilmemiştir.

Bu çalışmada, dalgacık sinir ağı (DSA) aktivasyon fonksiyonlarının, yaygın olarak kullanılan yapay sinir ağı (YSA) aktivasyon fonksiyonlarına karşı, rüzgar hızı tahmininde ne derece başarımlı oldukları gözlemlenmeye çalışılmıştır. Bu nedenle yapay sinir ağı ile dalgacık sinir ağı için aynı mimaride ağ yapıları oluşturulmuş, aynı veri setleri ile aynı öğrenme algoritmaları kullanılarak 40 m yükseklik için rüzgar hızı tahmini yapılmıştır.

Seçilen mimari basınç, sıcaklık ve nem için birer giriş, rüzgar hızı için bir çıkış olacak şekilde bir girdi katmanı, bir çıktı katmanı ve bir gizli katmanlı ağ yapısı şeklindedir. Gizli katmandaki nöron sayısı ile ilgili hesaplamalarda literatürde birden fazla yöntemin olduğu ve tam olarak kaç olması gerektiğine ilişkin belirli bir kural olmadığı görülmektedir [8]. Bir girdi katmanı, bir gizli katman ve bir çıktı katmanından oluşan üç katmanlı bir YSA için, gizli nöron sayısının, girdi katmanındaki nöron sayısının %75'i olması gerektiğini ileri sürmüştür. Katz, en uygun gizli nöron sayısının, giriş katmanındaki nöron sayısının 1,5 katı ile 3 katı arasında

olduğunu ileri sürmektedir [9]. Doig'e göre ise gizli katmanda olması gereken nöron sayısının gizli katman sayısına göre çok daha fazla alternatiflere sahip olduğundan uygun sayıyı belirlemek üzere aşağıdaki formülden yararlanılabileceğini söylemiştir [10].

$$N_s = \frac{\frac{1}{2}(N_g + N_c) + \sqrt{N_d}}{N_b}$$

N_s : Gizli katmandaki nöron sayısını
 N_g : Girdi katmanındaki nöron sayısını
 N_c : Çıktı katmanındaki nöron sayısını
 N_d : Gözlem sayısını
 N_b : Katman sayısını göstermektedir.

Bu formüle göre çalışmada oluşturulan yapay sinir ağı modellerinde 40 m yükseklikteki rüzgar hızı tahmin eden model için 144 gözlem sayısı için bir gizli katmandaki nöron sayısı 14 olarak hesaplanmıştır.

Gizli katmandaki nöron sayısı öncelikle 14 olarak denenmiştir ve daha sonra sayı azaltıp artırılarak tahmin sonuçları birbirleriyle kıyaslanmıştır. En iyi tahmin sonuçlarının 10 gizli nöron sayısına sahip modelde olduğu görülmüştür. Böylelikle bir girdi katmanı, bir çıktı katmanı ve bir gizli katmanlı ağ yapısı için tüm modellerde 10 nöron ya da 10 dalgacık nöronu kullanılmıştır.

D. Veri Setinin Hazırlanması

Yapay sinir ağlarında, ağ giriş ve çıkışlarına belirli ön işlem adımları uygulayarak yapay sinir ağına sunulan verilerin eğitimi daha verimli hale getirilebilir. Ağ giriş işlem fonksiyonları, ağ kullanımını daha iyi bir forma dönüştürür. Normalleştirme işlemi ham verilere uygulanarak ve bu verilerin eğitim için uygun veri setinin hazırlanmasına etkisi vardır. Yapay sinir ağların eğitimi, ham veri setine normalizasyon yöntemi uygulanmadan çok yavaş olabilir. Normalleştirme işlemlerinde farklı teknikler kullanılabilir. Literatürde birçok veri normalizasyon çeşidi vardır. Bunlar; Min kuralı, Max kuralı, Medyan, Sigmoid ve Z-Score gibi kuralları sıralanabilir [11].

Seçilen modelin girdi ve çıktıların ölçeklendirilmesi (normalizasyon) ağın performansını yakından etkilemektedir. Çünkü normalizasyon, veri setindeki değerlerin dağılımını düzenli hale getirmektedir. YSA girdileri arasında aşırı büyük veya küçük değerler görülebilir. Bunlar yanlışlıkla girdi setine girmiş olabilir. Net girdiler hesaplanırken bu değerler aşırı büyük veya küçük değerlerin doğmasına neden olarak ağı yanlış yönlendirebilirler. Bütün girdilerin belirli aralıkta (çoğunlukla 0-1 aralığında) ölçeklendirilmesi hem farklı ortamlardan gelen bilgilerin aynı ölçek üzerine indirgenmesine hem de yanlış girilen çok büyük ve küçük şeklindeki değerlerin etkisinin ortadan kalkmasına neden olur. Bazı araştırmacılar ise kendi problemlerine özgü ölçeklendirme yöntemleri geliştirmektedir. Her problem için farklı bir ölçeklendirme yöntemi kullanılabilir. Tasarımcılar, ellerindeki verileri normalize edecek bir yaklaşımı kendileri belirleyebilir. Bu konuda bir standart koymak doğru olmaz [12].

Bu çalışmada hazırlanan basınç, sıcaklık, nem ve rüzgar hızı verilerinin normalizasyonu için farklı teknikler üzerinde denemeler yapılmış ve en başarılı sonuçlar D_{Min_Max} Normalizasyonu tekniğinde ortaya çıkmıştır. Öncelikle modelin uygulanması için aşağıda verilen denklem ile tüm veriler 0,1 ile 0,9 arasında normalize edilmiştir.

Normalizasyon yapılarak veriler boyutsuz hale getirilmiş olur [13]. Bu yöntem için (1.9) nolu eşitlik kullanılır.

$$x' = 0,8 * \frac{x_i - x_{min}}{x_{max} - x_{min}} + 0,1$$

Bu eşitlikte;
 x' = Normalize edilmiş veriyi,
 x_i = Girdi değerini,
 x_{min} = Girdi seti içerisinde yer alan en küçük sayıyı,
 x_{max} = Girdi seti içerisinde yer alan en büyük sayıyı, ifade etmektedir.

E. Dalgacık Sinir Ağı Aktivasyon Fonksiyonlarının Belirlenmesi

Dalgacık sinir ağını oluştururken seçilen dalgacık aktivasyon fonksiyonu Tablo 1'de verilmiştir. Seçilen fonksiyon, daha önceden belirlenmiş olan bir girdi, bir gizli ve bir çıkış katmandan oluşan; üç girişi, on gizli katman nöronu ve bir çıkışı olan mimari ile on iki ay için test edilmiştir.

Tablo 1. Gauss Fonksiyonları ile Pencerelemiş Polinom Aktivasyon Fonksiyonu

Polywog1	$f(x) = x * e^{-\frac{x^2}{2}}$
----------	---------------------------------

F. Sinir Ağı Uygulaması

Bu çalışmada, Yapay Sinir Ağı (YSA) ve Dalgacık Sinir Ağı (DSA) çok kısa vadeli rüzgar hızı tahmini amacıyla kullanılmıştır. Oluşturulan mimari ve DSA için Tablo 1'de verilmiş olan dalgacık aktivasyon fonksiyonu ve YSA için ise tanjant sigmoit (tansig) ve logaritmik sigmoid (logsig) kullanılarak yapılan tahmin modelinde; basınç, nem, sıcaklık ve 40 metre yükseklikteki rüzgar hızı verileri 1 saat geri yayımlı olarak ağın eğitilmesinde kullanılmıştır. Ağın eğitimi tamamlandıktan sonra 10 dakika ilerideki rüzgar hızı tahmin edilmeye çalışılmıştır. Her iki sinir ağı için de öğrenme algoritması olarak Levenberg-Marquart algoritması kullanılmıştır.

G. Sinir Ağlarının Performansının Belirlenmesi

Model performansının ölçümü için kullanılan birinci ölçü, aşağıdaki eşitliği ile verilen toplam karesel hatanın ortalaması alınarak aşağıdaki gibi hesaplanır (ortalama karesel hata, mean squared error, MSE). Hata kareleri ortalaması sayısal kestirimler için en çok kullanılan başarı ölçülerinden biridir. Bu değer, her hesaplanan değer ve onun karşılık gelen doğru değer arasındaki farkın karelerinin ortalaması alınarak hesaplanır.

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

Model performansının ölçümü için kullanılan ikinci ölçü yukarıdaki eşitliği ile verilen ortalama karesel hatanın karekökünün alınması suretiyle belirlenen hatadır (Hata Karelerinin Ortalamasının Karekökü, Root Mean Squared Error-RMSE). RMSE model veya kestirimci tarafından kestirimi yapılan değerler ve modellenen veya kestirimi yapılandırılan elde edilen gerçek değerler arasındaki farkın ölçüsü olarak sıklıkla kullanılır [14].

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

RMSE basitçe MSE'nin kareköküdür. RMSE hata değerini gerçek ve kestirilen değerdeki gibi aynı boyutta verir.

Tablo 2. Yılın ilk çeyreğine ait her bir aktivasyon fonksiyonuna ait RMSE ve MSE değerleri

Ağ Tipi	Aktivasyon Fonksiyonu		OCAK	ŞUBAT	MART
YSA	TANSIG	RMSE	0,0869	0,0510	0,0343
		MSE	0,0075	0,0026	0,0012
	LOGSIG	RMSE	0,0843	0,0604	0,0372
		MSE	0,0075	0,0036	0,0014
DSA	POLYWOG1	RMSE	0,0685	0,0542	0,0318
		MSE	0,0047	0,0029	0,0010

Tablo 3. Yılın ikinci çeyreğine ait her bir aktivasyon fonksiyonuna ait RMSE ve MSE değerleri

Ağ Tipi	Aktivasyon Fonksiyonu		NİSAN	MAYIS	HAZİRAN
YSA	TANSIG	RMSE	0,1246	0,0565	0,0947
		MSE	0,0155	0,0032	0,0090
	LOGSIG	RMSE	0,1129	0,0428	0,0913
		MSE	0,0127	0,0018	0,0083
DSA	POLYWOG1	RMSE	0,0997	0,0415	0,0860
		MSE	0,0099	0,0017	0,0074

Tablo 4. Yılın üçüncü çeyreğine ait her bir aktivasyon fonksiyonuna ait RMSE ve MSE değerleri

Ağ Tipi	Aktivasyon Fonksiyonu		TEMMUZ	AĞUSTOS	EYLÜL
YSA	TANSIG	RMSE	0,0948	0,0627	0,0701
		MSE	0,0090	0,0039	0,0049
	LOGSIG	RMSE	0,0928	0,0694	0,0777
		MSE	0,0086	0,0048	0,0060
DSA	POLYWOG1	RMSE	0,0823	0,0426	0,0642
		MSE	0,0068	0,0018	0,0041

Tablo 5. Yılın dördüncü çeyreğine ait her bir aktivasyon fonksiyonuna ait RMSE ve MSE değerleri

Ağ Tipi	Aktivasyon Fonksiyonu		EKİM	KASIM	ARALIK
YSA	TANSIG	RMSE	0,0787	0,0231	0,0356
		MSE	0,0062	0,0005	0,0013
	LOGSIG	RMSE	0,0748	0,0227	0,0289
		MSE	0,0056	0,0005	0,0008
DSA	POLYWOG1	RMSE	0,0627	0,0189	0,0286
		MSE	0,0039	0,0004	0,0008

III. SONUÇLAR

Sürekli ve düzensiz verilerin gelecek değerlerinin tahmin edilmesinde defalarca başarımlarını kanıtlamış olan dalgacık ve yapay sinir ağı modelleri bir araya getirilerek, rüzgar hızının gelecek değerlerinin tahmin edilmesi için dalgacık aktivasyon fonksiyonlarını kullanan yapay sinir ağı modeli ile rüzgar hızı verilerinin tahminlemesi yapılmış ve bu yeni hibrit sinir ağı modeli ile geleneksel yapay sinir ağı başarımları karşılaştırılmıştır. Başarım etmeni olarak belirlenen MSE ve RMSE değerleri ayrıntılı olarak Tablo 2, Tablo 3, Tablo 4 ve Tablo 5'te verilmiştir. Ağların test edilmesi sırasında giriş verisi içerisinde eğitim verileri de kullanılmıştır. Ancak ağı başarımı hesaplanırken, sadece eğitim verileri dışında yapılan tahmin edilen değerler kullanılmıştır.

Elde edilen sonuçlar incelendiğinde; dalgacık aktivasyon fonksiyonları, geleneksel yapay sinir ağı fonksiyonlarından seçilen tanjant sigmoig (tansig) ve logaritmik sigmoid (logsig) fonksiyonlarına göre, 12 ay boyunca yapılan çok kısa vadeli tahminlerde, her ay için daha iyi sonuçlar verdiği gözlenmiştir.

IV. TARTIŞMA

Geleneksel yapay sinir ağı modeli ile tahmin yapılırken, başarılı sonuçlar elde edebilmek için çok sık yapılan işlem, ağı en iyi öğrenme derecesine gelene kadar sürekli eğitmek ve bu noktaya ulaşıldığında nöron ağırlıkları kaydedilerek simülasyon işlemini bu ağırlık değerleri ile yapmaktır. Ancak ortaya koymuş olduğumuz dalgacık sinir ağı yapısında, tahmin edilecek her bir an için, o an ki veriden geri yayılım yapılarak, sadece ve sadece bir kez eğitilerek tahmin işlemi yapılmış ve yukarıda belirtilen sonuçlara ulaşılmıştır.

Elde edilen veriler sonucunda, DSA kullanılarak yapılan tahminlerin, YSA kullanılarak yapılan tahminlere göre daha başarılı olduğu sonucuna varılmıştır.

Bu çalışmamız göstermiştir ki; rüzgar hızının gelecek değerleri için yapılan başarılı tahmin işlemi rüzgar türbinlerinde elde edilecek enerjinin önceden tespit edilerek, enerji güvenilirliğinin artışı ve sisteme girebilecek rüzgar kaynaklı aşırı zorlamaları önceden öngörülerek, sistem güvenliğini sağlayacaktır. Bu sayede daha etkin enerji üretimi yapılabilecek, rüzgar tarlalarındaki türbinlerin çalışma güvenliği arttırarak olası kazaların önüne geçilebilecek ve ayrıca makro düzeyde enerji piyasasında oluşabilecek dalgalanmaların öngörülebilmesine imkan sağlayacaktır.

REFERENCES

- [1] Taşçıkaraoğlu A., Uzunoglu M., "Dalgacık Dönüşümü ve Yapay Sinir Ağları ile Rüzgar Hızı Tahmini", *Elektrik-Elektronik ve Bilgisayar Sempozyumu FEEB 2011*, Fırat Üniversitesi-Elazığ, 5-7 Ekim 2011.
- [3] Soman S. S., Zareipour H., Malik O., and Mandal P., "A review of wind power forecasting methods with different time horizons," in North American Power Symposium, Arlington, TX, Sep. 26-28, 2010. Tahminlerinin Zaman Bazında Sınıflandırılması.
- [47] Kalogirou, S. A., 2000. Artificial neural networks in renewable energy systems applications: a review, *Renewable and Sustainable Energy Reviews*, 5, 373 – 401.
- [48] Kalogirou, S.A., 1999. Applications of artificial neural networks in energy systems a review, *Energy Conversion & Management*, 40, 1073-1087.
- [49] Fu, L.M., 1994. *Neural Networks in Computer Intelligence*, McGraw-Hill International Editions.
- [50] Rumelhart D.E., Hinton, G.E., ve Williams, R.J.1986. *Learning internal representation by error propagation. Parallel distributed processing*, Vol. 1: Foundations, MIT Press, Cambridge, Mass.
- [4] Veitch D., 2005. Wavelet Neural Networks and their application in the study of dynamical systems, Yüksek Lisans Tezi, York Üniversitesi, Matematik Bölümü, York /İngiltere.
- [5] Baily, D., Thomson, D., "Developing Neural Network Application". AI Expert, 33-41, 1990.
- [6] Katz, J. O., "Developing Neural Network Forecasters for Trading", Technical Analysis of Stocks and Commodities, 58-70, 1992.
- [7] Doig, G., "Severity of Illness Scoring in the Intensive Care Unit: A Comparison of Logistic Regression and Artificial Neural Networks", PhD, The University of Western Ontario, 1999.
- [8] Jayalakshmi, T. and Santhakumaran A.; (2011), "Statistical Normalization and Back Propagation for Classification", International Journal of Computer Theory and Engineering, 3(1), pp. 1793-8201.
- [9] Öztemel, E; (2003), Yapay Sinir Ağları, Birinci Baskı, İstanbul: Papatya Yayıncılık.
- [10] Doğan, E., Işık S. ve Mehmet Sandalcı M., (2007), "Günlük Buharlaşmanın Yapay Sinir Ağları Kullanarak Tahmin Edilmesi", İMO Teknik Dergi, ss. 4119 -4131.
- [11] Challagulla, V.U.B. , Bastani, F.B., I-Ling Yen, Paul, (2005) "Empirical assessment of machine learning based software defect prediction techniques", 10th IEEE International Workshop on Object-Oriented Real-Time Dependable Systems, WORDS 2005, 2-4 Feb 2005, sayfa 263-270.