



# Kahramanmaraş Sütçü İmam University

## Journal of Engineering Sciences



Geliş Tarihi : 19.08.2024  
Kabul Tarihi : 13.09.2024

Received Date : 19.08.2024  
Accepted Date : 13.09.2024

### RÜZGÂR GÜCÜ TAHMİNİNDE UZUN KISA-SÜRELİ BELLEK: VERİ ÖRNEKLEME VE KÜMELEMENİN ETKİSİ

#### LONG SHORT-TERM MEMORY FOR WIND POWER ESTIMATION: THE EFFECT OF DATA SAMPLING AND CLUSTERING

Volkan YAMAÇLI<sup>1</sup> (ORCID: 0000-0003-0331-8818)

<sup>1</sup> Mersin Üniversitesi, Bilgisayar Mühendisliği Bölümü, Mersin, Türkiye

\*Sorumlu Yazar / Corresponding Author: Volkan YAMAÇLI, vyamacli@mersin.edu.tr

#### ÖZET

Rüzgâr enerjisi, temiz, yenilenebilir ve çevre dostu olarak geleneksel güç kaynaklarının en verimli alternatiflerinden biridir. Bununla birlikte, rüzgâr hızının ve dolayısıyla güç kalitesinin değişken doğasından dolayı, elektrik şebekesinin güvenliği ve güvenilirliğinin önünde bazı engeller oluşabilmektedir. Rüzgâr hızı ve gücü tahmini aracılığı ile güç planlaması sorununu çözebilmek için, en popüler yinelemeli sinir ağlarından (YNSA) biri olan uzun kısa-sürelî bellek (UKSB) tabanlı bir tahmin modeli önerilmektedir. Bu çalışmada Türkiye’de mevcut olan bir rüzgâr türbininden elde edilen ve yayımlanan bir veri seti kullanılmıştır. İlk olarak UKSB ağı, rüzgâr hızı ve rüzgâr gücü zaman-dizilerine ilişkin farklı pencere boyutundaki veriler için eğitilmiştir. Daha sonra bu iki UKSB ağının çıktıları başka bir UKSB ağı için girdi olarak kullanılarak daha yüksek aralıklarla daha az miktarda veri için sağlam bir yaklaşım sağlanması hedeflenmiştir. Nihai rüzgâr gücü tahmin verileri, her bir dizinin sonuçları kullanılarak elde edilir. 30-dakikalık, 1-saatlik, 6-saatlik ve 1-günlük aralıklarla 4 farklı durum çalışması yapılarak önerilen algoritmanın etkinliği gösterilmiştir.

**Anahtar Kelimeler:** Rüzgâr enerjisi, uzun kısa-sürelî bellek, yinelemeli sinir ağları, rüzgâr güç tahmini.

#### ABSTRACT

Wind energy is one of the most efficient substitutes for traditional power sources, which is clean, renewable and friendly to the environment. Nonetheless, there are some of obstacles to the security and dependability of power grid functioning due to the erratic nature of wind speed and power quality. In order to address scheduling problem through wind speed and power prediction, a long short-term memory (LSTM)-based prediction model, one of the most popular recurrent neural networks (RNN), is proposed. In this study, the dataset obtained from a wind turbine placed in Turkey is used. At first, the LSTM network is trained for different window size of data for wind speed and power sequences. Then, the outputs of these two LSTM networks are used as an input for another LSTM network ensuring a robust approach for lower amount of data with higher intervals. The final wind power forecasting data are obtained by using each sequences’ results. Four different case studies are carried out based on intervals of 30-minutes, 1-hour, 6-hours, and 1-day in order to the efficiency of the proposed algorithm is shown.

**Keywords:** Wind energy, long short-term memory, recurrent neural networks, wind power forecasting.

#### GİRİŞ

Enerji, modern toplumun hızlı ilerlemesinin ve dünya ekonomisinin başarılı gelişiminin önemli bir bileşenidir ve insanın enerjiye olan ihtiyacı her zaman artmaktadır (Shi vd., 2020). Bununla birlikte; kömür, petrol ve doğal gaz gibi geleneksel fosil yakıt kaynaklarının aşırı kullanımı ile enerji kaynaklarının tükenmesi ve çevreye verilen zarar arasında önemli bir ilişki vardır. Dolayısıyla son zamanlarda rüzgâr, güneş, dalga gibi yenilenebilir enerji santrallerine olan ihtiyaç önemli ölçüde artmakla birlikte, bu santrallerin en verimli biçimde kullanılabilmesi de ToCite: YAMAÇLI, V., (2025). RÜZGÂR GÜCÜ TAHMİNİNDE UZUN KISA-SÜRELİ BELLEK: VERİ ÖRNEKLEME VE KÜMELEMENİN ETKİSİ. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 28(1), 202-215.

çalışma konusu haline gelmiştir. Dünya genelinde rüzgâr enerjisinin toplam kurulu kapasitesi son yıllarda 743 GW değerine ulaşmıştır ve 2019 yılından bu yana yeni kurulan rüzgâr enerjisi kapasitesi 93 GW olup %53'lük bir büyümeyi temsil etmektedir (Ai vd., 2022). Rüzgâr enerjisi, yeşil yenilenebilir bir enerji kaynağı olarak ekonomik kalkınma için muazzam bir potansiyele sahiptir ve ilgili tahmin teknolojisi araştırmaları giderek daha önemli hale gelmektedir. Rüzgâr gücü tahmini için rüzgâr hızının tahmin edilmesi gereklidir. Rüzgâr enerjisinin günlük ritmi, yüksek stokastik öngörülemezliği ve döngüsel doğası, güvenilir rüzgâr enerjisi tahminini imkânsız hale getirebilmektedir. Yerel ve bölgesel iklimler, arazi koşulları ve binalar gibi engeller rüzgâr enerjisini etkilediğinden, rüzgâr enerjisi kaynaklarının optimum dönüşümü ve uygulanması için bölgenin rüzgâr özelliklerine ilişkin doğru ve kapsamlı bilginin gerekli olduğu açıktır. Ancak rüzgâr kaynaklarının öngörülemeyen, istikrarsız ve düzensiz doğası, güç sisteminin istikrarlı bir şekilde çalışabilmesi için önemli sorunlar ve engeller yaratmıştır. Kısaca, rüzgâr enerjisi kaynaklarının optimum şekilde dönüştürülmesi ve uygulanması için bölgenin rüzgâr özellikleri hakkında doğru ve kapsamlı veriler gerekmektedir. Bilim adamları son zamanlarda, tarihsel rüzgâr hızı zaman serilerine dayanarak çeşitli tahmin yaklaşımları geliştirmişlerdir. Bunların arasında en popüler olan son zamanlarda daha aktif kullanılan derin öğrenme metotlarına dayanmaktadır. Rüzgâr hızı tahminleri, farklı zaman dilimlerine göre ultra kısa vadeli birkaç saniye ile 30 dakika arası; kısa vadeli 30 dakika ile 6 saat arası, orta vadeli 6 ile 24 saat arası ve uzun vadeli 1 ila 7 gün arası olarak sınıflandırılabilir (Jung & Broadwater, 2014). Yukarıda belirtilen sorunları çözmek için geleneksel rüzgâr enerjisi tahmin araçları tam anlamıyla yeterli değildir. Bu nedenle son yıllarda ortaya atılan yapay zekâ teknolojilerinin uygulanması zorunlu bir hal almıştır. İnsan zekasını taklit etmek, genişletmek ve geliştirmek için fikirlerin, tekniklerin, teknolojilerin ve uygulama sistemlerinin incelenmesi, bilgisayar bilimi yapay zekâ alanının odak noktasıdır.

Son yıllarda literatürde rüzgâr hızı tahmini ile ilgili birçok yeni çalışma mevcuttur. Rüzgâr hızı verilerini eğitirken ve tahmin ederken, regresörler, Çok Değişkenli Doğrusal Regresyon (ÇDDR) ve Yapay Sinir Ağı (YSA) dahil olmak üzere akıllı öğrenme teknikleri, rüzgâr hızındaki doğrusal olmayan değişimleri ayarlarken daha iyi performans gösterir (Bokde vd., 2019). Ayrıca rüzgâr hızı ve dolayısıyla rüzgâr gücü tahmininde YSA'lar sıklıkla kullanılabilir. YSA'ların avantajları güçlü, kendi kendine öğrenme yeteneklerini ve iyi doğrusal olmayan uyumu içerir. Bununla birlikte, gizli katmanların sayısı da dahil olmak üzere ağ yapısının oluşturulması zordur ve yavaş yakınsama oranı, yerel optimum değere kaymayı kolaylaştırır. Ultra kısa vadede rüzgâr hızının mekânsal dağılımını tahmin etmek için, evrişimli sinir ağlarına (ESA) dayanan bir rüzgâr hızı tahmin modeli, rüzgâr hızının zamansal ve mekânsal korelasyonunu hesaba katabilir. Ayrıca, geri yayımlı sinir ağları (GYSA), destek vektör makineleri (DVM), aşırı öğrenme makineleri (AÖM), bulanık mantık yöntemleri ve Kalman filtre yöntemleri gibi yapay zekâ tabanlı teknikler, rüzgâr alanında önemli ölçüde artmıştır (Shao vd., 2021). Bilgisayar biliminin hızla ilerlemesiyle hız tahmini, doğrusal olmayan özellikleri çıkarma ve genelleme yeteneği ile bu yapay zekâ tabanlı modeller, rüzgâr hızı eğilimlerinin doğrusal olmayan ilişkisini yakalamada çok başarılı olabilmektedir (Sun & Wang, 2018), rüzgâr hızı tahmini için GYSA'nın bileşik yapısını önermiş ve uygulamıştır, bununla birlikte modelin doğruluğunu ve dayanıklılığını arttırmak için (J. Wang vd., 2013), rüzgâr enerjisi tahmini için geliştirilmiş model arama algoritmasına dayalı bir DVM önermiştir. Çok sayıda faktör rüzgâr hızını etkilemektedir ki ve hiçbir tahmin modeli sayısal fonksiyonlara bağlı olarak bu durumu ifade edememektedir. Tek bir model, özellikle aşırı değişken koşullarında yeterli öğrenmeye sahip değildir ve bu da tahminden önemli ölçüde sapmaya neden olabilir. Çeşitli tekli modelleri uygun şekilde birleştirerek ve her modelin faydalarını vurgulayarak, birleşik tahmin yaklaşımı, aynı anda birkaç modelin avantajlarını hesaba katar ve tahmin doğruluğunu büyük ölçüde artırabilir (J. Wang vd., 2020). Rüzgâr hızı verileri, dalgacık ayrıştırması (Gan vd., 2021; Lopez vd., 2020) ve değişken mod ayrıştırması (DMA) (Li vd., 2020; Xie vd., 2021) kullanılarak da iyileştirilmiş ve doğru sonuçlar tahmin edilebilmiştir. Ayrıca, kısa vadeli rüzgâr hızı tahmin modelini ek tahmin teknikleri ile birlikte geliştirerek, Hilbert-Huang dönüşümü (HHD) (Chen vd., 2024) ve diğer teknikler rüzgâr hızı verilerinin girdi özelliklerini çıkarmayı ve iyi tahmin sonuçları üretmeyi başarabilmektedir.

Bir YNSA versiyonu olarak, uzun kısa-süreli bellek (UKSB), uzun vadeli bağımlılık sorunlarını ele alabilir ve doğuştan gelen gizli özellikleri ortaya çıkarabilir. Bir çalışmada, (Memarzadeh & Keynia, 2021) tarafından elektriğin fiyatını ve yükünü tahmin etmek için UKSB 'ye dayalı bir derin öğrenme tekniği geliştirilmiştir. (Lawal vd., 2021), kısa vadede rüzgâr hızını etkili bir şekilde tahmin etmek için çift yönlü UKSB ve 1-boyutlu ESA kombinasyonunu kullanmıştır. Bununla birlikte, bir optimizasyon algoritması olan parçacık sürüsü optimizasyonu (PSO), (Al-Shaikhi vd., 2022) tarafından hibrit bir UKSB modelinde kullanarak iyi bir sonuç elde etmiştir. Bununla birlikte, özellikle son yıllarda, rüzgâr enerjisine dair çalışmaları içeren birçok çalışma mevcuttur. Bu çalışmalar rüzgâr enerjisinin genel ve geniş güç sistemlerinde kullanımına yönelik veya rüzgâr enerjisi tahminine yönelik olabilmektedir. Rüzgâr enerjisi içeren güç sistemlerine dair farklı optimizasyon çalışmaları gerçekleştirilmiştir (Abaci vd., 2024). Bazı çalışmalarda

ise farklı olarak hem rüzgâr hem de güneş enerjisi sistemlerinin elektriksel açıdan optimizasyonu sağlanmıştır (Yamaçlı vd., 2024). Ek olarak, (Guan vd., 2023) tarafından ultra-kısa-sürelili rüzgâr gücü tahminine yönelik çalışmalar gerçekleştirilmiştir.

Rüzgâr enerjisi, son yıllarda dünyada kullanılan en yüksek yenilenebilir enerji potansiyeline sahiptir (Hou vd., 2024). Bu potansiyel ve profil güneş enerjisine nazaran çok daha yüksektir. Bununla beraber, literatürde mevcut olan çalışmalar genellikle rüzgârla ilgili verilerin herhangi bir ön veri işlemesi veya gruplandırılması yapılmadan UKSB veya benzer metotlar ile tahminine yöneliktir. Dolayısıyla, sadece rüzgâr hızı veya gücü değil, rüzgâr kaynaklı üretime etki eden birçok faktörün göz önüne alınması ve tahmine yönelik çalışmalarda kullanılması gereklidir. Bu sebeple, bu çalışmada rüzgâr enerjisi tahminine yönelik YNSA tabanlı bir zaman serisi analizine dayalı olarak Türkiye veri setinde ölçülen rüzgâr hızı verileri üzerinde farklı gruplandırma ve UKSB girdi kombinasyonları ile rüzgâr gücü tahminine odaklanılmaktadır. İlk olarak UKSB tabanlı rüzgâr hızı tahmin modeli oluşturulmuştur. UKSB ağı, rüzgâr hızı ve rüzgâr gücü dizilerine ilişkin farklı pencere boyutundaki veriler için eğitilmiştir. Bununla birlikte farklı pencere boyutlarında 4 farklı durum çalışması yapılarak önerilen algoritmanın etkinliği gösterilmiştir. Daha sonra, önerilen UKSB modeli için verilerin örnekleme ve kümeleme parametrelerine odaklanılarak rüzgâr tahmininin başarı oranının artışı gözlenmiş ve takip edilmiştir.

Bu makale verilen şekilde organize edilmiştir: Bölüm 2'de veri seti ile ilgili bilgiler sunularak veri setinin grafiksel örneklerine yer verilmiştir. Bölüm 3'te uzun kısa-sürelili bellek ve verilerin ön işlenmesi, örneklenmesi ve kümelemesine dair bilgiler ve açıklamalar sunulmuştur. Diğer bir bölümde, Bölüm 4'te, elde edilen sonuçların sunulması, nicel veriler olarak verilmesi ve teknik açıdan analizlerinin yapılması sağlanmış, ve son olarak Bölüm 5'te yapılan çalışmadan elde edilen ana çıkarımlar, genel katkılar ile sunulmuş ve yorumlanmıştır.

## VERİ SETİ


Bu çalışmada, Kaggle web sayfası üzerinden yayınlanmış ve bazı çalışmalarda kullanılmış 2018 yılına ait verileri içeren *Wind Turbine Scada Dataset* (Erisen, 2018) veri seti hem Türkiye'de olması hem de rüzgâr hızı dışında rüzgâr gücü ve sıcaklık gibi parametreleri içermesi sebebiyle seçilmiştir. Veri setindeki verilere ait bazı örnek değerler Tablo 1 ile verilmiştir.

Bu veri setinde 10 dakika aralıklarla verilen verilere ait olmak üzere; zaman, üretilen aktif güç değeri, rüzgâr hızı, teorik güç değerleri ve rüzgâr geliş açısı mevcuttur. Veri seti toplamda 50.530 adet satır içermektedir ve bu da 1 yıllık süre içinde %96'lık bir oranda verilerin kaydedildiği sonucu ortaya çıkmaktadır. Veriler detaylı biçimde incelediğinde bazı hücrelerin değerleri 0 olarak atanmıştır, bu da rüzgâr hızının sınır değerden düşük olması gibi sebeplerle güç üretilmediği veya veri alınmadığını ifade etmektedir. Fakat bu durumda olan veri oranı çok düşük sayıdadır.

**Tablo 1.** Veri Setinde Mevcut Olan Bazı Örnek Değerler


Tarih	Aktif Güç (kW)	Rüzgâr Hızı (m/sn)	Teorik Güç (kW)	Rüzgâr Açısı (derece)
01.01.2018 00:00	380.047790527343	5.311336	416.328907824861	259.994904
01.01.2018 00:10	453.769195556640	5.672167	519.917511061494	268.641113
01.01.2018 00:20	306.376586914062	5.216037	390.900015810951	272.564789
01.01.2018 00:30	419.645904541015	5.659674	516.127568975674	271.258087
01.01.2018 00:40	380.650695800781	5.577941	491.702971953588	265.674286
...	...	...	...	...
...	...	...	...	...
24.05.2018 01:30	24.9452304840087	3.394524	41.0767121951976	217.449493
24.05.2018 01:40	44.0470390319824	3.686321	75.6453312993517	215.859100
24.05.2018 01:50	0	2.141613	0	251.522094
24.05.2018 02:00	0	2.824742	0	302.344604
...	...	...	...	...
...	...	...	...	...
31.12.2018 23:20	1684.35302734375	7.332648	1173.05577118814	84.062599
31.12.2018 23:30	2201.10693359375	8.435358	1788.28475526396	84.742500
31.12.2018 23:40	2515.69409179687	9.421366	2418.38250336009	84.297913
31.12.2018 23:50	2820.46606445312	9.979332	2779.18409628274	82.274620

Veri setinde verilen rüzgâr hızı ve rüzgâr gücüne dair grafikler ise Şekil 1 ile sunulmuştur. Şekilden de anlaşılacağı üzere, türbinlerin güç üretim karakteristiklerine bağlı olarak, rüzgâr hızının rüzgâr gücü üzerinde direkt olarak etkili olduğu söylenememektedir fakat rüzgâr hızı yine de tahmini bir fikir verebilmektedir. Bu veri setinde özellikle rüzgâr gücünün zamana dayalı tahmini ve rüzgâr gücünün rüzgâr hızına tahminine yönelik çalışmalar gerçekleştirilebilmektedir. Bu makalede de farklı durumlar için rüzgâr gücü, rüzgâr hızı ve rüzgâr açısına dair çalışma, analiz ve tahminlere dair çalışmalara yer verilmiştir.



Şekil 1. a. Zamana Göre Rüzgâr Hızı b. Zamana Göre Üretilen Rüzgâr Gücü

Bununla birlikte rüzgâr gücünün, rüzgâr hızı ve yönüne bağlı değişimi de Şekil 2'de verilmiştir. Şekil 2.a'dan görüleceği üzere rüzgâr hızının 12 m/s'nin üzerinde olduğu zamanlarda verim en iyidir fakat bazı durumlarda rüzgâr hızının yüksek olmasına rağmen beklenenden düşük bir güç üretimi de belirlenmiştir. Bununla birlikte, Şekil 2.b incelendiğinde, yaklaşık 45° ile 200° derece dağılımında rüzgâr gücünün en yüksek değerlere ulaştığı da görülebilmektedir.



Şekil 2. a. Rüzgâr Hızına Göre Rüzgâr Gücü b. Gücün Rüzgâr Geliş Açısına Göre Değişimi

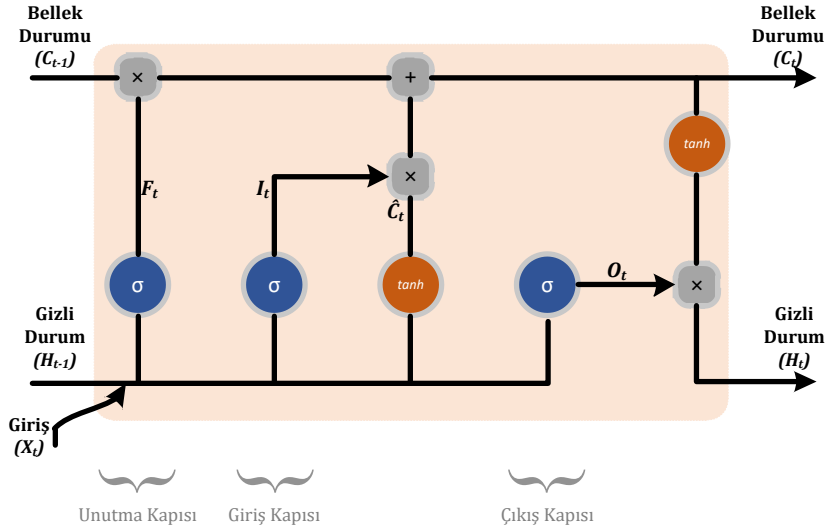
## METODOLOJİ

### Uzun Kısa-Süreli Bellek

Popüler bir YNSA sınıfı olan UKSB (Hochreiter & Schmidhuber, 1997), zaman serisiyle ilgili sorunları ele almak için literatürde sıklıkla kullanılan ve başarı gösteren yöntemlerden biridir. Birçok zaman serisi tahmin metodundan UKSB gibi dikkate değer performans sergileme kabiliyetine sahiptir; ancak birçok YNSA, eğitim sırasında gradyan kaybolmasına eğilimli olduğundan, uzun vadeli bağımlılıkların öğretilmesi ve tahmini kolay olmamaktadır (Jun

Zhang & Man, 1998). UKSB ağları için üç farklı türde belirgin kapı yapısı ve belirli bir yapısal birim tasarlanmıştır. Birim üzerinden geçen verilere seçici eklemeler ve çıkarmalar yapılır. Kapı yapısını oluşturmak için sigmoid fonksiyonu kullanılmaktadır. İçerisinden akabilen maksimum bilgi miktarını temsil eden sigmoid katsayısı 0 ile 1 arasında değişmektedir.

Önceki bellek durumundan hangi bilginin unutulacağına karar vermek için, LSTM birimi önce verileri unutma kapısı aracılığıyla işler. Bellekte tutulan bilgi daha sonra LSTM birimi tarafından belirlenir ve aynı zamanda giriş kapısı bir yandan hangi verilerin güncelleneceğini seçer. Diğer bir taraftan da tanh katmanı aday vektörü güncellenir. Yukarıdaki iki bileşen daha sonra UKSB birimi tarafından bellek durumunu güncellemek için birleştirilir. Son olarak, çıkış kapısı UKSB birimi tarafından çıkış yapılması gereken bellek durumunu düzenlemek için kullanılır (C. Wang vd., 2019). UKSB'nin genel mimarisi Şekil 3 ile verilmiştir.



Şekil 3. Uzun Kısa-Süreli Bellek Genel Mimarisi

$C_{t-1}$ ,  $H_{t-1}$  ve  $O_t$  mevcut bellek durumu, gizli durum ve çıkış durumu olmak üzere,  $F_t$ ,  $I_t$  ve  $\hat{C}_t$  ise sırasıyla unutulacak bellek bilgisi, giriş bilgisi ve aday vektörü olarak ifade edilmektedir. Bu değişkenlere ait denklemler (1)-(3) ile verilmiştir. Denklemlerde  $W$ , ilgili kapının ağırlığı ve  $b$  ise ilgili kapının yanlılık değişkenidir.

$$F_t = \sigma\{W_F \times (H, X_t) + b_F\} \quad (1)$$

$$I_t = \sigma\{W_I \times (H_{t-1}, X_t) + b_I\} \quad (2)$$

$$\hat{C}_t = \tanh\{W_C \times (H_{t-1}, X_t) + b_C\} \quad (3)$$

Verilen bu denklemler kullanılarak,  $C_t$ ,  $O_t$  ve  $H_t$ 'nin eldesi de aşağıdaki biçimde, (4)-(6) ile ifade edilebilir. Denklemlerdeki  $\odot$  simgesi eleman-eleman çarpım işlemini ifade etmektedir (Gers vd., 2000).

$$C_t = F_t \odot C_{t-1} + I_t \odot \hat{C}_t \quad (4)$$

$$O_t = \sigma\{W_O \times (H_{t-1}, X_t) + b_O\} \quad (5)$$

$$H_t = \sigma \odot \tanh(C_t) \quad (6)$$

### Verilerin Ön-İşlemesi

Veri setinde direkt olarak rüzgâr gücünü etkileyen en temel veri rüzgâr hızıdır, fakat bununla birlikte Şekil 2.b'den de anlaşılacağı üzere rüzgârın yönü de üretilen aktif gücün dağılımını etkilemektedir. Veriler üzerinde yapılan incelemelerde, özellikle, yaklaşık 18 m/s değerinden yüksek hızlarda, rüzgâr yönünün çoğunlukla 200° civarında olduğu gözlenmiştir. Tabii ki bu durum rüzgâr türbinlerinin yönü ile ilgili olabilmektedir dolayısıyla bu çalışmada hem rüzgâr hızı hem de rüzgârın yönünün etkisinin üretilen güce etkisi ve tahmin edilmesine dair çalışmalar için

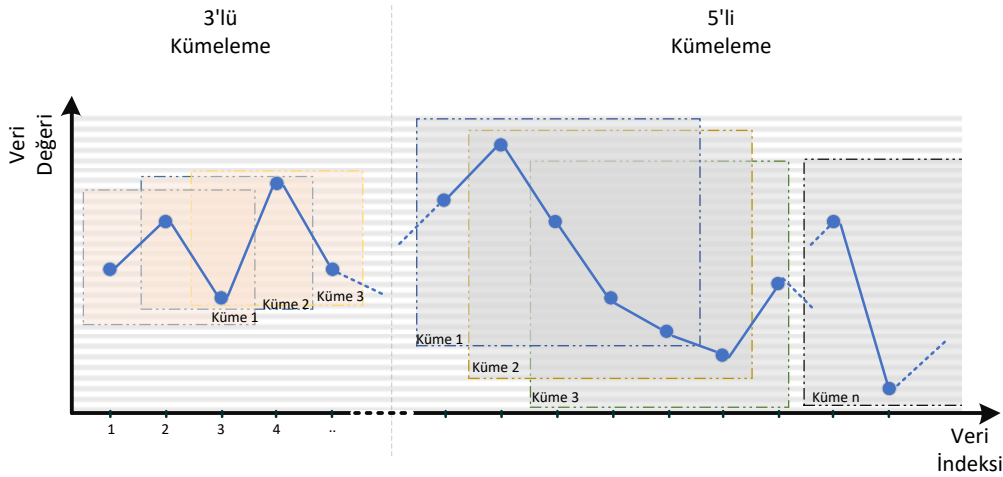
kullanılan veri setindeki veriler Tablo 2 ile sunulan biçimde örneklenerek her durum için farklı bir UKSB eğitim, validasyon ve test çalışması sağlanmıştır.

**Tablo 2.** Uzun Kısa-Sürelili Bellek Eğitimde Kullanılan Parametreler

Durum Çalışması	Örnekleme Aralığı	Veri Sayıları*			Kullanılan Girdi(ler)			Çıktı
		Eğitim	Validasyon	Test	Rüzgâr Gücü (RG)	Rüzgâr Hızı (RH)	Rüzgâr Yönü (RY)	
Durum 1.1	30 Dk.	6738	5053	5053	-	✓	-	RH
Durum 1.2	6 saat	559	420	420	-	✓	-	RH
Durum 2.1	30 Dk.	6738	5053	5053	✓	-	-	RG
Durum 2.2	1 Gün	141	105	105	✓	-	-	RG
Durum 3.1	30 Dk.	6738	5053	5053	✓	✓	-	RG
Durum 3.2	1 Gün	141	105	105	✓	✓	-	RG
Durum 3.3	30 Dk.	6738	5053	5053	✓	✓	✓	RG
Durum 3.4	6 Saat	559	420	420	✓	✓	✓	RG
Durum 3.5	1 Gün	20	16	16	✓	✓	✓	RG

\*Tabloda verilen veri sayıları tek bir parametreye aittir. Kullanılan girdi sayısı arttıkça kullan veri sayısı oransal biçimde artmaktadır.

Bununla birlikte kullanılan parametreler her durum çalışması için 3, 5 ve 10'luk zaman serileri halinde eğitime sunulmuştur. Örneğin Durum 1.1 için, 6738 adet eğitim verisi mevcuttur ve bu veriler 3'erli, 5'erli ve 10'arlı kümeler halinde çalışılmıştır. Verilerin kümeleneşine dair genel şematik Şekil 4 ile verilmiştir. Bu işlem Tablo 2'de verilen tüm durum çalışmaları için ayrı ayrı gerçekleştirilmiştir.



**Şekil 4.** Zaman Serisi Verilerinin Kümelere Ayrılması

### Hata Metrikleri

Bu çalışmada, elde edilen sonuçların birbiriyle karşılaştırılabilmesi için literatürde yaygın olarak kullanılan bazı hata metrikleri kullanılmıştır. Bu tür zaman serisi tahmine yönelik çalışmalarda, sistem çıktısının girişe nazaran hata oranı ve seviyesini ifade eden bazı göstergeler de mevcuttur. Bunların en çok kullanılanları; ortalama-karesel-hata (OKH) ve kök-ortalama-karesel-hata (KOKH) metrikleridir. OKH (Pavlov-Kagadejev vd., 2024) ve KOKG (Akçay & Yiltas-Kaplan, 2024) genel denklemleri sırasıyla (7) ve (8) ile verilmiştir.

$$OKH = \frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i)^2, \quad n: \text{değişken sayısı}, \quad \hat{x}_i: \text{tahmin değeri}, \quad x_i: \text{gerçek değer} \quad (7)$$

$$KOKH = \sqrt{\frac{1}{n} \sum_{i=1}^n (\hat{x}_i - x_i)^2}, \quad n: \text{değişken sayısı}, \quad \hat{x}_i: \text{tahmin değeri}, \quad x_i: \text{gerçek değer} \quad (8)$$

### BULGULAR

Önerilen yaklaşımın etkinliğini değerlendirmek; veri örnekleme ve kümeleneşinin etkisini görebilmek amacıyla, kullanılan veri setindeki üretilen rüzgâr gücü, rüzgâr hızı ve rüzgâr yönü parametreleri 1-boyutlu, 2-boyutlu ve 3-boyutlu UKSB ile işlenmiştir. Yapılan çalışmalar, Python yazılımı (versiyon 3.10.1) ve Tensorflow derin öğrenme kütüphanesi (versiyon 2.10.1) kullanılarak Visual Studio Code™ üzerinde Nvidia GeForce RTX™ 3080 donanımına

sahip *Windows 11*<sup>TM</sup> yüklü bilgisayarda gerçekleştirilmiştir. Sistem versiyonunu gösteren bilgiler Şekil 5 ile verilmiştir.

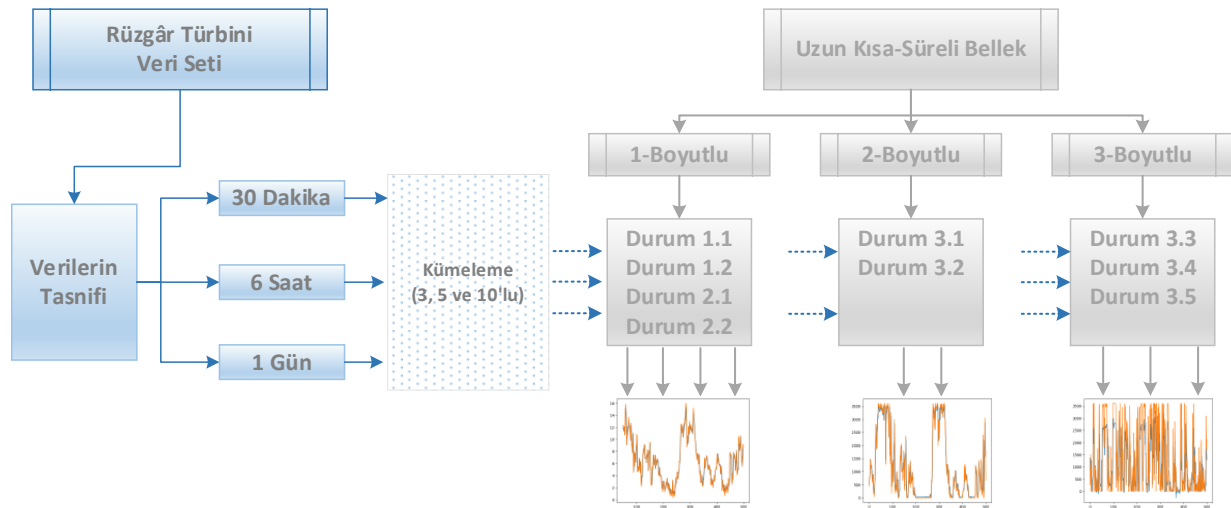
```
C: > Users > volkn > Desktop > vrsion.py
1 import sys
2 import tensorflow as tf
3 from tensorflow.python.client import device_lib
4
5 print(sys.version)
6 print(tf.__version__)
7 print(device_lib.list_local_devices())
```

```
PS C:\Users\volkn\Desktop\xpception_bend> & C:/Users/volkn/AppData/Local/Programs/Python/Python310-1 (tags/v3.10.1:2cd268a, Dec 6 2021, 19:10:37) [MSC v.1929 64 bit (AMD64)]
2.10.1
2024-08-14 14:19:26.938156: I tensorflow/core/platform/cpu_feature_guard.cc:193]
library (oneDNN) to use the following CPU instructions in performance-critical operations.
To enable them in other operations, rebuild TensorFlow with the appropriate compiler flags.
2024-08-14 14:19:27.442526: I tensorflow/core/common_runtime/gpu/gpu_device.cc:162]
name: NVIDIA GeForce RTX 3080, pci bus id: 0000:01:00:00, compute capability: 8.6
[name: "/device:CPU:0"
device_type: "CPU"
memory_limit: 268435456
```

Şekil 5. Kullanılan Sistem Versiyon ve Özellikleri

Bununla birlikte, UKSB için oluşturulan model kullanılırken, UKSB birim sayısı 10 olarak seçilmiş, ayrıca aktivasyon durumu ise *none* olarak belirlenmiştir. Özellikle aktivasyonun *none* olarak seçilme sebebi, yüksek varyasyona sahip rüzgâr gücü gibi verilerde gerçeğe daha yakın sonuç elde etmektir. Model eğitilirken ise döngü sayısı 10 olarak seçilmiş, öğrenme oranı ise 0.01 olarak belirlenmiştir.

Bu çalışmada, veri örnekleme ve kümeleme gibi sinyal işleme yöntemleri ve literatürde zaman serilerinin tahmini için kullanılan en temel ve efektif ağlardan biri olan uzun kısa-süreli bellek tabanlı rüzgâr gücü tahminini amaçlayan farklı durum çalışmaları gerçekleştirilmiştir. Önerilen yaklaşımı test etmek için, Türkiye sınırları içerisinde olan ve veri seti olarak paylaşılan bir rüzgâr gücü karakteristiği için, farklı örneklem frekansları ve kümeleme parametreleri kullanılarak, farklı boyutlu UKSB ağları eğitilmiş ve test edilmiştir. Önerilen metodolojinin genel blok diyagramı Şekil 6'da verilmiştir.




Şekil 6. Önerilen Metodun Genel Şematığı


### Durum Çalışması-1

Bu durum çalışması rüzgâr geliş hızı ile ilgili iki farklı alt çalışma içermektedir. Bunlardan ilki, 30-dakikalık örneklemelerle, bir diğeri ise 6-saatlik örneklemelerle gerçekleştirilen eğitim ve test sonuçlarıdır. Durum 1.1 ve Durum 1.2'ye ait test değerlerine ait grafikler Şekil 7 ve Şekil 8'de sunulmuştur.

Tablo 3 ile de eğitim, validasyon ve test verilerine dair hata metrikleri de verilmiştir. Hata değerleri hem gerçek değerler hem de normalize değerler olarak sunulmuştur. Test çalışmalarına dair hata değerleri incelendiğinde görülmektedir ki, en iyi sonuç 10'lu kümeleme neticesinde elde edilebilmektedir. Ayrıca, diğer kümeleme değerleri incelendiğinde, Durum 1.1 için 5'li kümeleme daha iyi sonuç verirken, Durum 1.2'de ise 3'lü kümelemede daha iyi sonuç alınabilmektedir. Bunun yanı sıra,



**Şekil 7.** Durum 1.1 Farklı Kümeleme Değerleri İçin Test ve Gerçek Rüzgâr Hızı Sonuçları **a.** Küme Değeri: 3 **b.** Küme Değeri: 5 **c.** Küme Değeri: 10



**Şekil 8.** Durum 1.2 Farklı Kümeleme Değerleri İçin Test ve Gerçek Rüzgâr Hızı Sonuçları **a.** Küme Değeri: 3 **b.** Küme Değeri: 5 **c.** Küme Değeri: 10

**Tablo 3.** Durum Çalışması-1 İçin Elde Edilen Hata Değerleri


Durum Çalışması	Küme Değeri	OKH		KOKH	
		Gerçek	Normalize	Gerçek	Normalize
Durum 1.1 Eğitim	3	0,1931	0,0003	0,4394	0,0191
	5	0,1557	0,0003	0,3946	0,0171
	10	0,0852	0,0004	0,2919	0,0194
Durum 1.1 Validasyon	3	0,1295	0,0009	0,3599	0,0298
	5	0,0926	0,0009	0,3043	0,0310
	10	0,0888	0,0006	0,2980	0,0238
Durum 1.1 Test	3	0,1465	0,0004	0,3827	0,0204
	5	0,1132	0,0002	0,3365	0,0159
	10	0,0533	0,0002	0,2308	0,0165
Durum 1.2 Eğitim	3	3,0050	0,0051	1,7335	0,0714
	5	7,1660	0,0155	2,6769	0,1245
	10	2,0363	0,0045	1,4270	0,0670
Durum 1.2 Validasyon	3	1,4127	0,0072	1,1886	0,0851
	5	1,4782	0,0103	1,2158	0,1014
	10	1,0581	0,0063	1,0286	0,0792
Durum 1.2 Test	3	2,2193	0,0056	1,4897	0,0746
	5	5,5594	0,0164	2,3578	0,1279
	10	1,4437	0,0040	1,2016	0,0629




## Durum Çalışması-2

Bu durum çalışması rüzgâr gücüne dair Tablo 2 ile verilen iki farklı durum çalışması içermektedir. Bunlardan ilki, 30-dakikalık örneklemelerle, bir diğeri ise 1-saatlik örneklemelerle gerçekleştirilen rüzgâr gücü tahminine yönelik eğitim ve test sonuçlarıdır.

Durum 2.1 ve Durum 2.2'ye ait test performansını gösterir grafikler Şekil 9 ve Şekil 10 ile sunulmuştur. Bununla birlikte, Tablo 4 ile verilen hata değerleri incelendiğinde, Durum 2.1 için normalize hata değerleri 10'lu kümelemeye en düşük sonucu vermiştir bunlar eğitim, validasyon için sırasıyla; OKH için 0.0005, 0.0004 ve 0.0003; KOKH için ise 0.0228, 0.0204 ve 0.0170'dir. Bunun yanı sıra Durum 2.2 içinse, 5'li kümeleme ile en düşük hata değeri dolayısıyla en yüksek performans elde edildiği görülmektedir ve en yüksek normalize hata değeri, OKH için 0.0698 ve KOKH için ise 0.2643 olarak elde edilmiştir.



Şekil 9. Durum 2.1 Farklı Kümeleme Değerleri İçin Test ve Gerçek Rüzgâr Gücü Sonuçları a. Küme Değeri: 3 b. Küme Değeri: 5 c. Küme Değeri: 10



Şekil 10. Durum 2.2 Farklı Kümeleme Değerleri İçin Test ve Gerçek Rüzgâr Gücü Sonuçları a. Küme Değeri: 3 b. Küme Değeri: 5 c. Küme Değeri: 10

## Durum Çalışması-3

Bu alt bölümde, farklı UKSB boyutlarında farklı girişlere sahip durumlar için gerçekleştirilen, 30-dakikalık, 6-saatlik ve 1-günlük örneklemeler kullanılarak çeşitli durum çalışmalarına dair sonuçlar sunulmuştur. Tablo 2 incelendiğinde, hem 1- hem 2- hem de 3-boyutlu UKSB çalışmalarının gerçekleştirildiği görülebilmektedir. Durum çalışmalarına ait test performansları Tablo 5 ile sunulmuş; bununla birlikte tüm alt durum çalışmalarına dair grafikler de Şekil 11 ile verilmiştir.

Durum 3.1 için en optimal normalize hata değerleri OKH ve KOKH için sırasıyla 0.0008 ve 0.0349 olarak 5'li ve 3'lü kümeleme değerleri için elde edilmiştir. Burada özellikle 10'lu kümeleme yaklaşımının hatasının oransal olarak yüksek olduğu tespit edilmiştir. Durum 3.2'de en düşük normalize hata değerleri OKH ve KOKH için 0.0827 ve 0.2875 olarak elde edilmiş; burada da en iyi sonuç kümeleme sayısı 3 olduğu durumda elde edilmiştir. Bununla birlikte, Durum 3.3 ve Durum 3.4'te ise OKH ve KOKH için sırasıyla 5'li ve 3'lü kümeleme yaklaşımında en iyi normalize hata elde edilmiştir; hata oranları sırasıyla OKH ve KOKH için 0.0003 ve 0.0277 ile 0.0192 ve 0.1663'tür.

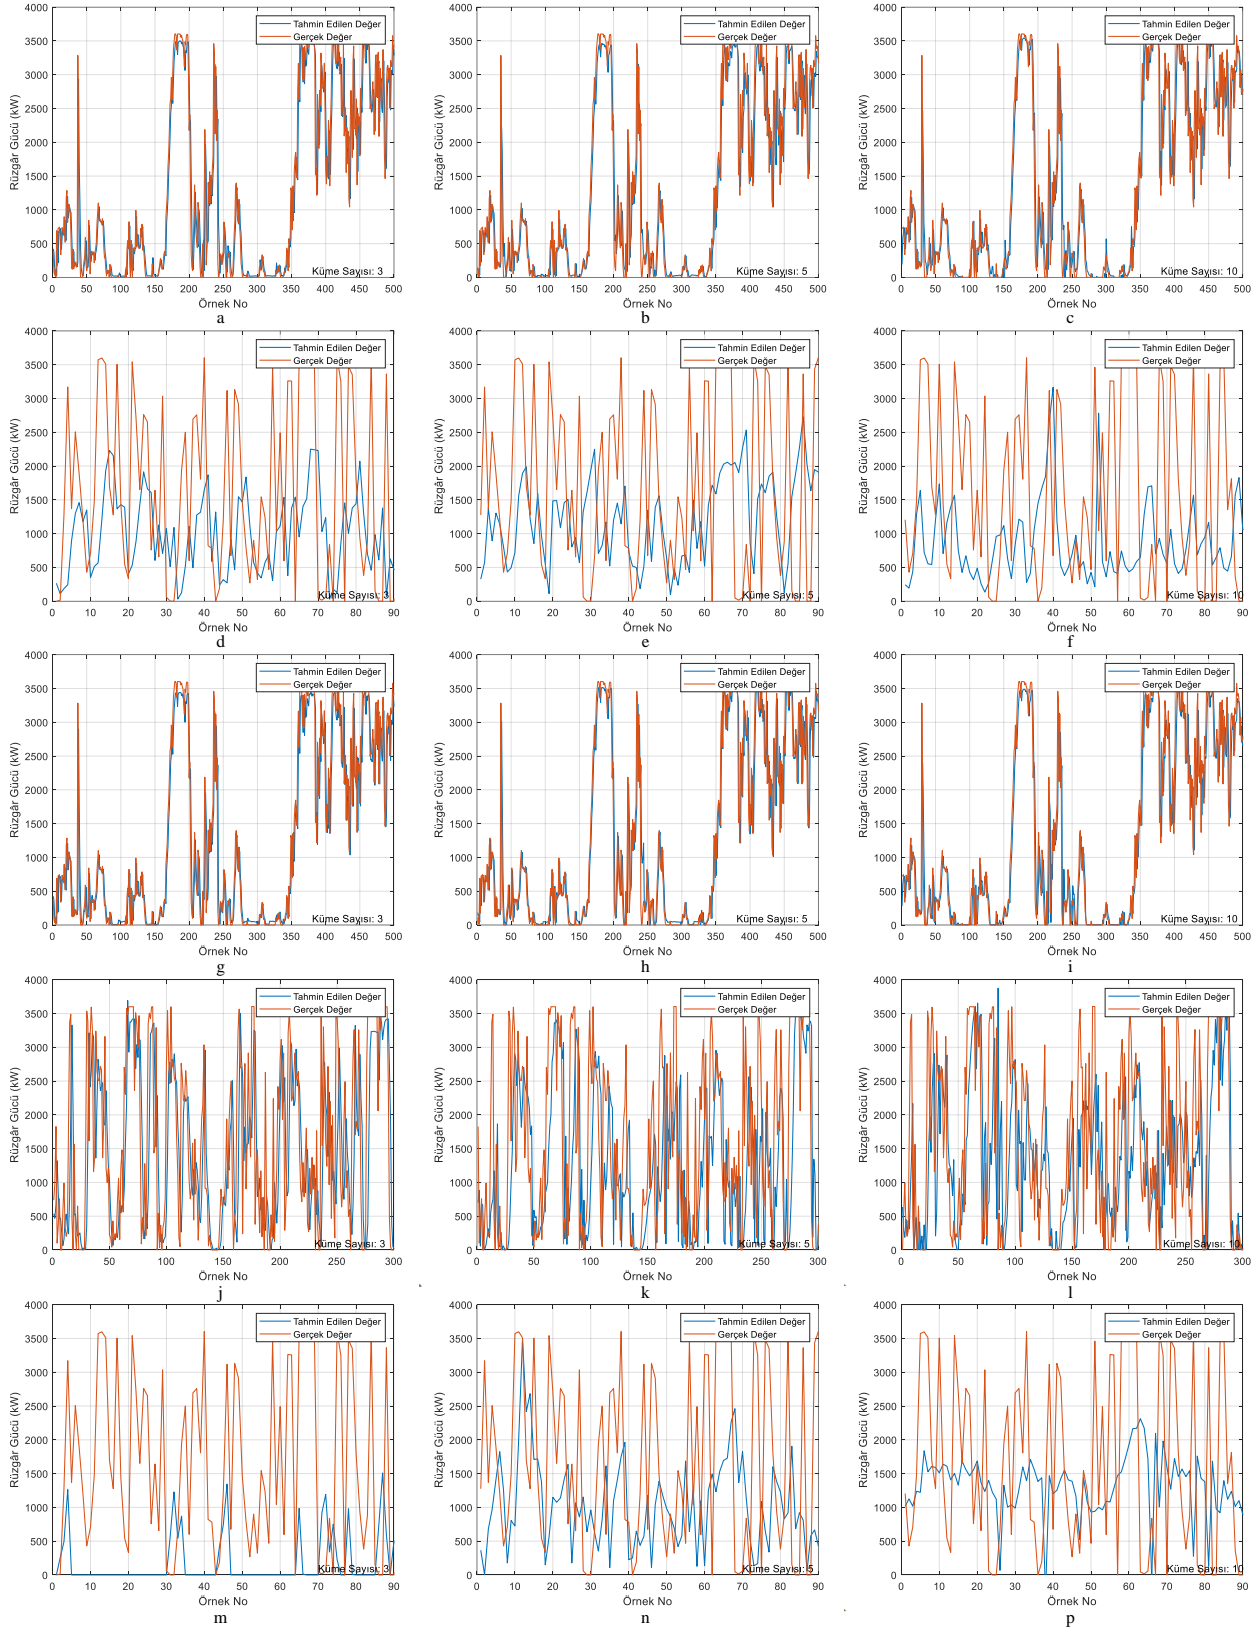
Durum 3.5 incelendiğinde, en düşük normalize hata 10'lu kümeleme durumunda elde edilmiş, fakat 5'lü kümeleme durumundaki hata oranı da optimal sonuca çok yakındır. Tablo 2'de verilen durumların örnekleme parametreleri göz önüne alındığında, örnekleme sıklığı azaldıkça kümeleme sayısının artışının sonuca olumlu etki ettiği; aynı zamanda çok boyutlu UKSB'nin de önceki durumlara nazaran daha iyi sonuçlara imkân sağladığı görülebilmektedir.

**Tablo 4.** Durum Çalışması-2 İçin Elde Edilen Hata Değerleri

Durum Çalışması	Küme Değeri	OKH		KOKH	
		Gerçek	Normalize	Gerçek	Normalize
Durum 2.1 Eğitim	3	1427,30	0,0125	119,46	0,1116
	5	8061,50	0,0009	89,78	0,0304
	10	9412,90	0,0005	97,02	0,0228
Durum 2.1 Validasyon	3	1289,50	0,0009	113,55	0,0316
	5	7206,20	0,0007	84,88	0,0260
	10	7585,40	0,0004	87,09	0,0204
Durum 2.1 Test	3	1370,70	0,0009	117,07	0,0297
	5	7188,90	0,0007	84,85	0,0256
	10	6628,80	0,0003	81,41	0,0170
Durum 2.2 Eğitim	3	$1587,20 \times 10^3$	0,1201	1259,80	0,3465
	5	$7902,20 \times 10^2$	0,0582	888,94	0,2412
	10	$1417,10 \times 10^3$	0,1082	1190,40	0,3289
Durum 2.2 Validasyon	3	$9843,70 \times 10^2$	0,0759	992,15	0,2754
	5	$4572,40 \times 10^2$	0,0345	676,19	0,1857
	10	$1099,20 \times 10^3$	0,0830	1048,40	0,2881
Durum 2.2 Test	3	$2007,50 \times 10^3$	0,1520	1416,90	0,3899
	5	$9369,00 \times 10^2$	0,0698	967,93	0,2643
	10	$1923,50 \times 10^3$	0,1486	1386,90	0,3854

**Tablo 5.** Durum Çalışması-3 Test Performansı İçin Elde Edilen Hata Değerleri

Durum Çalışması	Küme Değeri	OKH		KOKH	
		Gerçek	Normalize	Gerçek	Normalize
Durum 3.1	3	8963,80	0,0012	94,67	0,0349
	5	15918,00	0,0008	126,16	0,0291
	10	14853,00	0,0075	121,87	0,0865
Durum 3.2	3	$1489,40 \times 10^3$	0,0827	1220,40	0,2875
	5	$1595,40 \times 10^3$	0,1124	1263,10	0,3353
	10	$3124,40 \times 10^3$	0,2406	1767,60	0,4905
Durum 3.3	3	10470,00	0,0011	102,32	0,0333
	5	6327,50	0,0003	79,54	0,0192
	10	15135,00	0,0008	123,02	0,0293
Durum 3.4	3	$3465,30 \times 10^2$	0,0277	588,67	0,1663
	5	$9040,40 \times 10^2$	0,0688	950,81	0,2623
	10	$6486,40 \times 10^2$	0,0545	805,38	0,2334
Durum 3.5	3	$4406,80 \times 10^3$	0,3923	2099,20	0,6264
	5	$1624,40 \times 10^3$	0,1221	1274,50	0,3494
	10	$1508,50 \times 10^3$	0,1211	1228,20	0,3481



**Şekil 11.** Durum Çalışması-3: Farklı Kümeleme Değerleri İçin Test ve Gerçek Rüzgâr Gücü Sonuçları **a.** Durum 3.1 Küme Değeri: 3 **b.** Durum 3.1 Küme Değeri: 5 **c.** Durum 3.1 Küme Değeri: 10 **d.** Durum 3.2 Küme Değeri: 3 **e.** Durum 3.2 Küme Değeri: 5 **f.** Durum 3.2 Küme Değeri: 10 **g.** Durum 3.3 Küme Değeri: 3 **h.** Durum 3.3 Küme Değeri: 5 **i.** Durum 3.3 Küme Değeri: 10 **j.** Durum 3.4 Küme Değeri: 3 **k.** Durum 3.4 Küme Değeri: 5 **l.** Durum 3.4 Küme Değeri: 10 **m.** Durum 3.5 Küme Değeri: 3 **n.** Durum 3.5 Küme Değeri: 5 **p.** Durum 3.5 Küme Değeri: 10

Bununla birlikte, tüm durum çalışmalarına ait verilerin en iyi değerleri Tablo 6 ile verilmiştir. Buradan görüleceği üzere, çalışmaların %40'ında 10lu kümeleme en iyi sonucu verirken; %30 oranında 5'li kümeleme ve %20 oranında ise 3'lü kümeleme en iyi sonuçları vermektedir. Buradan görülebilir ki, özellikle girdi boyutunun çok olduğu yani girdi çeşidinin fazla olduğu durumlarda kümeleme sayısının düşük seçilmesi daha iyi sonuçlar elde edilmesini sağlayabilmektedir.

**Tablo 6.** Tüm Durum Çalışmalarındaki Test Verileri İçin Elde Edilen En İyi Değerler

Durum Çalışması	Küme Değeri	OKH		KOKH	
		Gerçek	Normalize	Gerçek	Normalize
Durum 1.1	10	0,0533	0,0002	0,2308	0,0165
Durum 1.2	10	1,4437	0,0040	1,2016	0,0629
Durum 2.1	10	6628,80	0,0003	81,41	0,0170
Durum 2.2	5	9369,00×10 <sup>2</sup>	0,0698	967,93	0,2643
Durum 3.1	3	8963,80	0,0012	94,67	0,0349
Durum 3.2	3	1489,40×10 <sup>3</sup>	0,0827	1220,40	0,2875
Durum 3.3	5	6327,50	0,0003	79,54	0,0192
Durum 3.4	3	3465,30×10 <sup>2</sup>	0,0277	588,67	0,1663
Durum 3.5	10	1508,50×10 <sup>3</sup>	0,1211	1228,20	0,3481

## SONUÇLAR

Bu çalışmada, rüzgâr enerji sistemlerinden üretilen güç tahmini problemini ele almak üzere farklı örnekleme ve kümeleme seçenekleri ile uyarlanmış UKSB tabanlı bir zaman serisi tahmin çalışması gerçekleştirilmiştir. Oluşturulan algoritma ile öncelikle rüzgâr hızı tahmini gerçekleştirilmiş ve elde edilen sonuçlar farklı hata metrikleri ile sunulmuştur. Daha sonra çok boyutlu UKSB ağı için girdiler hem rüzgâr hızı hem rüzgâr gücü hem de rüzgâr yönü olacak şekilde belirlenerek farklı boyut sayısına sahip ağlar ile eğitilmiştir. Elde edilen sonuçlar göstermektedir bir yıllık rüzgâr verileri ile yapılan bu çalışmada örnekleme ve kümelemenin sonuca oranda etki ettiği, özellikle yıl içinde değişken karakteristiğe sahip rüzgâr gücünün örnekleme sıklığından yüksek miktarda etkilendiği gözlenmiştir. Normalize hata metrikleri incelendiğinde, örnekleme sıklığının düşük olmasının çıktı olarak elde edilen sinyalin genliğini etkilemekte olmasına rağmen, normalize karakteristiğinin gerçek sinyal karakteristiğine yakın olduğu kolaylıkla görülebilmektedir. Yapılan tüm durum çalışmalarında, en yüksek normalize OKH 0.3923 ve en yüksek normalize KOKH ise 0.6264 olarak elde edilmiştir. Bu durum da rüzgâr gücünün değişkenlik oranı ve skalasını yüksek olması ile açıklanabilir. Sonuçların tamamı incelendiğinde ise, girdilerin karmaşıklığı arttığında kümelemenin etkisinin düştüğü görülebilmektedir. Bu durumun önüne geçebilmek için yapılacak çalışmalarda, farklı UKSB yapıları kullanılabilir veya farklı ağ modelleri ile birlikte hibrit çalışmalar gerçekleştirilebilir. Bunun yanı sıra, rüzgâr gücü gibi değişkenlik oranı yüksek elde edilen verilerin başarı ile işlenebilmesi ve geleceğe yönelik tahmini göstermiştir ki benzer biçimde karakteristiğe sahip olan güneş ve dalga enerjilerinin tahmini için de geçerli olabilecektir. Ayrıca, bir elektrik üretim sistemindeki rüzgâr ve güneş enerji santrallerinin eş zamanlı tahmini ve kısa vadeli enerji planlaması da gerçekleştirilebilir. Bu çalışmanın ana katkıları aşağıdaki gibi ifade edilebilir,

1. Bir, iki ve üç boyutlu UKSB ağlarının kısa ve uzun süreli rüzgâr gücü tahmini için başarı ile kullanılabildiği gösterilmiştir.
2. Rüzgâr hızı ve gücü tahmininde örnekleme sıklığının ve kümeleme parametrelerinin sonuca etkisi ve önemi sayısal nicelikler ile ifade edilebilmiş ve sunulmuştur.
3. Değişkenlik karakteristiği yüksek olan sinyallerde dâhi sinyalin normalize karakteristiğinin başarı ile elde edilebilmesi sağlanmıştır.

## KAYNAKLAR

Abaci, K., Yetgin, Z., Yamaçlı, V., & Isiker, H. (2024). Modified effective butterfly optimizer for solving optimal power flow problem. *Heliyon*, 10(12), e32862. <https://doi.org/10.1016/j.heliyon.2024.e32862>

Ai, X., Li, S., & Xu, H. (2022). Short-term wind speed forecasting based on two-stage preprocessing method, sparrow search algorithm and long short-term memory neural network. *Energy Reports*, 8, 14997-15010. <https://doi.org/10.1016/j.egy.2022.11.051>

Akçay, H., & Yılmaz-Kaplan, D. (2024). Zaman serileri tahminleme algoritmaları ile kontör tüketim tahminlemesi ve karşılaştırmalı uygulaması. *Kahramanmaraş Sütçü İmam Üniversitesi Mühendislik Bilimleri Dergisi*, 27(1), 166-189. <https://doi.org/10.17780/ksujes.1369811>

- Al-Shaikhi, A., Nuha, H., Mohandes, M., Rehman, S., & Adrian, M. (2022). Vertical wind speed extrapolation model using long short-term memory and particle swarm optimization. *Energy Science & Engineering*, 10(12), 4580-4594. <https://doi.org/10.1002/ese3.1291>
- Bokde, N., Feijóo, A., Villanueva, D., & Kulat, K. (2019). A Review on Hybrid Empirical Mode Decomposition Models for Wind Speed and Wind Power Prediction. *Energies*, 12(2), 254. <https://doi.org/10.3390/en12020254>
- Chen, J., Guo, Z., Zhang, L., & Zhang, S. (2024). Short-term wind speed prediction based on improved Hilbert–Huang transform method coupled with NAR dynamic neural network model. *Scientific Reports*, 14(1), 617. <https://doi.org/10.1038/s41598-024-51252-y>
- Erisen, B. (2018). Wind Turbine Scada Dataset. <https://www.kaggle.com/datasets/berkerisen/wind-turbine-scada-dataset>
- Gan, Z., Li, C., Zhou, J., & Tang, G. (2021). Temporal convolutional networks interval prediction model for wind speed forecasting. *Electric Power Systems Research*, 191, 106865. <https://doi.org/10.1016/j.epsr.2020.106865>
- Gers, F. A., Schmidhuber, J., & Cummins, F. (2000). Learning to Forget: Continual Prediction with LSTM. *Neural Computation*, 12(10), 2451-2471. <https://doi.org/10.1162/089976600300015015>
- Guan, S., Wang, Y., Liu, L., Gao, J., Xu, Z., & Kan, S. (2023). Ultra-short-term wind power prediction method combining financial technology feature engineering and XGBoost algorithm. *Heliyon*, 9(6), e16938. <https://doi.org/10.1016/j.heliyon.2023.e16938>
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Computation*, 9(8), 1735-1780. <https://doi.org/10.1162/neco.1997.9.8.1735>
- Hou, X., Hu, W., & Luo, M. (2024). Short-term wind farm cluster power point-interval prediction based on graph spatio-temporal features and S-Stacking combined reconstruction. *Heliyon*, 10(14), e33945. <https://doi.org/10.1016/j.heliyon.2024.e33945>
- Jun Zhang, & Man, K. F. (1998). Time series prediction using RNN in multi-dimension embedding phase space. *SMC'98 Conference Proceedings. 1998 IEEE International Conference on Systems, Man, and Cybernetics (Cat. No.98CH36218)*, 1868-1873. <https://doi.org/10.1109/ICSMC.1998.728168>
- Jung, J., & Broadwater, R. P. (2014). Current status and future advances for wind speed and power forecasting. *Renewable and Sustainable Energy Reviews*, 31, 762-777. <https://doi.org/10.1016/j.rser.2013.12.054>
- Lawal, A., Rehman, S., Alhems, L. M., & Alam, Md. M. (2021). Wind Speed Prediction Using Hybrid 1D CNN and BLSTM Network. *IEEE Access*, 9, 156672-156679. <https://doi.org/10.1109/ACCESS.2021.3129883>
- Li, M., Zhang, Z., Ji, T., & Qu, Q. H. (2020). Ultra-short term wind speed prediction using mathematical morphology decomposition and long short-term memory. *CSEE Journal of Power and Energy Systems*. <https://doi.org/10.17775/CSEEJPES.2019.02070>
- Lopez, L., Oliveros, I., Torres, L., Ripoll, L., Soto, J., Salazar, G., & Cantillo, S. (2020). Prediction of Wind Speed Using Hybrid Techniques. *Energies*, 13(23), 6284. <https://doi.org/10.3390/en13236284>
- Memarzadeh, G., & Keynia, F. (2021). Short-term electricity load and price forecasting by a new optimal LSTM-NN based prediction algorithm. *Electric Power Systems Research*, 192, 106995. <https://doi.org/10.1016/j.epsr.2020.106995>
- Pavlov-Kagadejev, M., Jovanovic, L., Bacanin, N., Deveci, M., Zivkovic, M., Tuba, M., Strumberger, I., & Pedrycz, W. (2024). Optimizing long-short-term memory models via metaheuristics for decomposition aided wind energy generation forecasting. *Artificial Intelligence Review*, 57(3), 45. <https://doi.org/10.1007/s10462-023-10678-y>
- Shao, B., Song, D., Bian, G., & Zhao, Y. (2021). Wind Speed Forecast Based on the LSTM Neural Network Optimized by the Firework Algorithm. *Advances in Materials Science and Engineering*, 2021, 1-13. <https://doi.org/10.1155/2021/4874757>
- Shi, Z., Yao, W., Li, Z., Zeng, L., Zhao, Y., Zhang, R., Tang, Y., & Wen, J. (2020). Artificial intelligence techniques for stability analysis and control in smart grids: Methodologies, applications, challenges and future directions. *Applied Energy*, 278, 115733. <https://doi.org/10.1016/j.apenergy.2020.115733>

Sun, W., & Wang, Y. (2018). Short-term wind speed forecasting based on fast ensemble empirical mode decomposition, phase space reconstruction, sample entropy and improved back-propagation neural network. *Energy Conversion and Management*, 157, 1-12. <https://doi.org/10.1016/j.enconman.2017.11.067>

Wang, C., Han, D., Liu, Q., & Luo, S. (2019). A Deep Learning Approach for Credit Scoring of Peer-to-Peer Lending Using Attention Mechanism LSTM. *IEEE Access*, 7, 2161-2168. <https://doi.org/10.1109/ACCESS.2018.2887138>

Wang, J., Sun, J., & Zhang, H. (2013). Short-term wind power forecasting based on support vector machine. 2013 5th International Conference on Power Electronics Systems and Applications(PESA), 1-5. <https://doi.org/10.1109/PESA.2013.6828211>

Wang, J., Wang, Y., Li, Z., Li, H., & Yang, H. (2020). A combined framework based on data preprocessing, neural networks and multi-tracker optimizer for wind speed prediction. *Sustainable Energy Technologies and Assessments*, 40, 100757. <https://doi.org/10.1016/j.seta.2020.100757>

Xie, Y., Li, C., Tang, G., & Liu, F. (2021). A novel deep interval prediction model with adaptive interval construction strategy and automatic hyperparameter tuning for wind speed forecasting. *Energy*, 216, 119179. <https://doi.org/10.1016/j.energy.2020.119179>

Yamaçlı, V., İşiker, H., Yetgín, Z., & Abacı, K. (2024). Solving Optimal Power Flow Control Problem Using Honey Formation Optimization Algorithm. *IEEE Access*, 12, 109293-109322. <https://doi.org/10.1109/ACCESS.2024.3439021>