

# The Effect of Data Decomposition on Prediction Performance in Wind Speed Prediction with Artificial Neural Network

Serkan Şenkal <sup>a,1</sup>, Cem Emeksiz <sup>b</sup>

<sup>a</sup> Mechatronics Engineering Department, Tokat Gaziosmanpaşa University, Tokat, Turkey  
ORCID ID: 0000-0002-4571-3923

<sup>b</sup> Electrical and Electronics Engineering, Tokat Gaziosmanpaşa University, Tokat, Turkey  
ORCID ID: 0000-0002-4817-9607

## Abstract

This study investigates the effect of data decomposition to improve the performance of artificial neural networks (ANNs), widely used in wind speed forecasting in the wind energy sector. Artificial neural networks are essential tools for planning and optimizing the daily generation of wind power plants. However, prediction errors can lead to significant problems in power generation and energy grid management. The results show that data decomposition substantially affects the wind speed forecasting performance of neural networks. These findings are essential for researchers and industry professionals interested in developing more accurate forecasting models for power generation planning and management in the wind energy sector. By integrating artificial neural networks and data disaggregation methods, the study stands out as an essential step forward to improve the accuracy of wind speed forecasts and optimize the efficiency of wind energy facilities.

**Keywords:** “Wind speed estimation, artificial neural networks, data decomposition.”

## 1. Giriş

Rüzgar enerjisi endüstrisinde, doğru rüzgar hızı tahmini, rüzgar enerjisi üretiminin tahmini ve bir türbinin enerji üretim verimliliğinin değerlendirilmesi için çok önemlidir [1]. Rüzgar enerjisi üretimi sadece rüzgar hızına değil, aynı zamanda rüzgar türbini jeneratör kapasitesinin özelliklerine de bağlıdır; bu nedenle, rüzgar kaynağı analizine güç eğrilerini ve jeneratör kapasitesini dahil etmek esastır [4]. Rüzgar hızının mevsimsel değişimi, rüzgar enerjisi tedarik programının tutarlılığı ile ilgili olarak rüzgar türbinlerinin kullanımının verimliliği hakkında temel bilgiler sağladığından, rüzgar potansiyelinin tahmin edilmesi için önemlidir [2]. Ayrıca, aşırı rüzgar hızları, kuleler ve kanatlar gibi rüzgar türbinlerinin hassas bileşenlerine zarar verebileceğinden, rüzgar hızının rastlantısallığı rüzgar enerjisi sistemlerinin mekanik güvenilirliği üzerinde önemli bir etkiye sahiptir [3].

Ayrıca, enerji yönetim sistemlerinin enerji arz ve talebini yönetebilmesi için rüzgar hızı tahmini gereklidir [1]. Rüzgar hızı tahmini, enerji arzı ile enerji talebinin koordine edilmesine yardımcı olarak verimli enerji yönetimi sağlar. Buna ek olarak, farklı rüzgar türbinleri farklı rüzgar giriş hızına, rüzgar nominal hızına ve rüzgar çıkış hızına sahiptir. Bu nedenle, sahanın rüzgar hızı profiline bağlı olarak uygun rüzgar türbinlerinin seçilmesi gerekir [9].

Yıllık ortalama rüzgar hızı tahminlerini etkileyen eksik rüzgar verilerindeki ve kısa kayıtlardaki hatalar ve belirsizlikler, ortalama rüzgar hızı ve bir rüzgar türbininden enerji üretiminin aylık ve yıllık tahminlerini önemli ölçüde etkileyebilir ve böylece rüzgar enerjisi kaynak değerlendirmelerinde belirsizliğe katkıda bulunabilir [10]. İklim değişikliği bağlamında, aşırı rüzgarların rüzgar enerjisi kullanılabilirliğini nasıl etkilediğini anlamak önemlidir ve araştırma çalışmaları, yüksek ve düşük aşırı rüzgar olaylarının sıklığında önemli değişiklikler olduğunu göstermiştir, bu da iklim değişikliğinin veya uzun vadeli iklim değişikliğinin açık deniz rüzgar enerjisi üretimini zaten etkilediğini kanıtlamaktadır [6][8].

Özetle, doğru rüzgar hızı tahmini, verimli enerji yönetimi sağladığı, rüzgar türbinlerinin kullanım verimliliği hakkında temel bilgiler sağladığı ve rüzgar enerjisi üretiminin karlılığını belirlediği için rüzgar enerjisi endüstrisinde kritik öneme sahiptir. Rüzgar hızı tahmini, rüzgar türbini verimliliğini etkileyebilecek rüzgar yönü, hava yoğunluğu, nem, türbülans yoğunluğu ve rüzgar makasları gibi çevresel faktörlere duyarlıdır ve doğru rüzgar enerjisi üretim tahmini için rüzgar gücü eğrisi modellerinde dikkate alınmalıdır [1].

<sup>1</sup> Corresponding Author

E-mail Address: serkan.senkal@gop.edu.tr

Bu çalışmada, meteorolojik veriler (basınç, sıcaklık, nem) kullanılarak yapay sinir ağı ile rüzgar hızı tahminlemesi yapılacaktır. Amacımız, yapay sinir ağının giriş verileri üzerinde yapılacak veri ayrıştırması işlemi ile daha basit, anlamlı ve işlenebilir hale getirilmiş veriler kullanarak yapılan tahminlemelerin sonuçlarını incelemek, ham veri kullanımı ile ayrıştırılmış veri kullanımı arasında yapay sinir ağının rüzgar hızı tahmin performansını karşılaştırmaktır. Karmaşık yapıların modellenmesi, büyük veri setlerini işleme yetenekleri ve non-linear ilişkileri öğrenme kabiliyetleri sayesinde öne çıkan yapay sinir ağlarının daha etkili tahminlemeler yapabilmesi için önerebileceğimiz olası yöntemler en büyük motivasyonumuzdur.

## 2. Materyal ve Yöntem

### 2.1. Veri Toplama Aracı

Bu çalışmada kullanılan meteorolojik veriler, Tokat Gaziosmanpaşa Üniversitesi, Taşlıçiftlik kampüsü içerisinde (N40°19'58.73") enlem ve (E36°29'0.28") boylam koordinatlarında bulunan meteorolojik ölçüm istasyonundan alınan 2020 yılına ait rüzgar hızı, basınç, sıcaklık ve nem verileridir. İlgili yıla ait ayların ilk günleri için, 10'ar dakika çözünürlüklü olacak şekilde, her bir veri grubu için bir haftalık (1008 adet) olacak şekilde gruplandırılmıştır. Oluşturulan veri grupları, Yapay Sinir Ağı (YSA) girişleri için kullanılacak veri setlerinin temelini oluşturmuştur.

### 2.2. Veri Setlerinin Oluşturulması

Veri normalizasyonu bilgisayar bilimleri, mühendislik ve tıp gibi çeşitli alanlarda kullanılan temel bir ön işleme adıdır. Normalleştirme, farklı özelliklerin veya değişkenlerin benzer bir ölçekte olmasını sağlamak için çok önemlidir; bu da birçok makine öğrenimi algoritmasının optimum performansı için gereklidir. Örneğin, doğrusal sınıflandırıcıların, özellikle de Destek Vektör Makinelerinin (DVM'ler), verilerin normalleştirilmesine duyarlı olduğu bilinmektedir; DVM'ler, iç çarpımı kosinüs benzerliği ile hizaladığı için normalleştirmeden yararlanma eğilimindedir [11]. Ağrı tanımaya yönelik fizyolojik sinyaller bağlamında, verileri belirli bir aralığa dönüştürmek için min-max normalleştirme kullanılır ve bu da belirli analizler için faydalı olan orijinal dağılımın korunmasına izin verir [12]. Ayrıca, yapı mühendisliğinde normalleştirme, özellikle farklı sensör türlerinden ölçümler içeren veri kümeleriyle uğraşırken önemlidir, çünkü farklı kaynaklardan gelen verilerin tutarlı bir ölçekte olmasını sağlar [13]. Ayrıca, tıbbi görüntüleme için özellik seçimi alanında, özellikleri standartlaştırmak için z-skor normalizasyonu kullanılır ve belirli analitik teknikler için gerekli olan 0 ortalama ve 1 standart sapmaya sahip olmalarını sağlar [14]. Bu nedenle, veri normalizasyonu çeşitli alanlarda kritik bir rol oynamakta, verilerin tutarlı bir ölçek ve dağılımda olmasını sağlayarak analitik ve makine öğrenimi yöntemlerinin etkili bir şekilde uygulanmasını sağlamakta, böylece sonuçların doğruluğunu ve yorumlanabilirliğini artırmaktadır.

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. Veri normalleştirme alanında, verileri ölçeklendirme ve belirli bir aralığa dönüştürme işlemi, veri ön işlemede çok önemli bir adımdır. Verilerin 0,1 ile 0,9 arasında normalleştirilmesi, çeşitli veri analizi ve makine öğrenimi görevlerinde yaygın bir gerekliliktir. Bu normalleştirmeyi gerçekleştirmek ve verilerin belirtilen aralıkta kalmasını sağlamak için çeşitli yöntemler kullanılabilir.

Verileri 0,1 ile 0,9 arasında normalleştirmeye yönelik yaklaşımlardan biri min-maks ölçeklendirmesidir. Bu yöntem, verilerin veri kümesindeki minimum ve maksimum değerlere göre ölçeklendirilmesini içerir. Min-maks ölçeklendirme formülü şu şekilde verilir:

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

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.

İstenen 0,1 ile 0,9 aralığını elde etmek için hem min-max ölçeklendirmenin hem de z-skor normalleştirmenin kullanılabilmesini belirtmek önemlidir. Bununla birlikte, yöntem seçimi veri kümesinin belirli özelliklerine ve analizin gerekliliklerine bağlı olabilir.

Sonuç olarak, 0,1 ile 0,9 arasındaki verilerin normalleştirilmesi min-max ölçekleme ve z-skor normalleştirme gibi çeşitli yöntemlerle gerçekleştirilebilir. Bu teknikler, verilerin analiz ve modelleme için hazırlanmasında önemli bir rol oynar ve verilerin anlamlı bilgilerini korurken belirtilen aralıkta kalmasını sağlar. Tahminciye giriş verisini sağlayacak olan basınç, sıcaklık ve nem verileri, yukarıda verilen denklem ile 0,1 ile 0,9 arasında normalize edilmiştir. Ayırıştırma işlemi kullanılan yapılarda ise veriler önce ayırıştırma işlemine tabi tutulmuş, sonrasında tahminciye giriş yapılmadan 0,1 ile 0,9 arasında normalizasyon işlemi uygulanmıştır.

### 2.3. Yapay Sinir Ağları (YSA)

Yapay sinir ağlarının (YSA) tarihi, çeşitli alanlara yayılan uygulamalarla zengin ve çeşitlidir. YSA'lar diş hekimliği, tıp, jeoloji, emlak, ulaşım altyapısı ve daha birçok alanda kullanılmıştır [15] [16] [17] [18] [19]. YSA kavramı, 1943 yılında yapay bir nöronun ilk resmi modelini sunan Warren McCulloch ve Walter Pitts'in çalışmalarına dayanmaktadır [17]. Zaman içinde YSA'lar, yenilikçi teknolojik çözümlerin uygulanmasında, karmaşık sistemlerin yönetilmesinde, sesli mesajların işlenmesinde ve ekonomi, finans ve sağlık hizmetlerinde yaygın olarak kullanılan en çok talep edilen bilgi işleme araçlarından biri haline gelmiştir [17]. YSA'ların gelişimi, evrensel yaklaşım problemlerinin çözümünde de önemli ilerlemeler kaydetmiştir [20].

Tıp alanında, YSA'lar demografik verileri kullanarak kanser hastalıklarını teşhis etmek ve sayısallaştırılmış göğüs radyografilerinde bulunan akciğer nodüllerinin tespiti için düşük çözünürlüklü görüntülerde şüpheli bölgeleri tespit etmek için kullanılmıştır [21]. Ayrıca, YSA'lar deprem zaman geçmişine dayalı olarak betonarme binaların hasar seviyesini tahmin etmede kullanılmış ve mimarlık mühendisliğindeki çok yönlülüklerini göstermiştir [22].

Jeoloji alanında, YSA'lar jeomekanik özelliklerin yapay olarak akıllı ve öngörücü bir şekilde modellenmesi için kullanılmış ve Bakken Formasyonu için sentetik jeomekanik kuyu loglarının oluşturulmasını sağlamıştır [16]. Ayrıca, YSA'lar yanal yayılma vaka geçmişlerine dayalı olarak artık kayma mukavemeti oranının tahmin edilmesinde kullanılmış ve sıvılaşma kaynaklı yanal yayılmanın değerlendirilmesindeki uygulamalarını göstermiştir [23].

Ayrıca, YSA'lar, gayrimenkul mülklerinin toplu değerlemesinde kullanılmalarıyla, iş ve değerlendirme süreçlerindeki önemlerini vurgulayarak gayrimenkul alanında uygulamalar bulmuştur [18]. Ulaşım sektöründe YSA'lar, özellikle bakım süreçlerinde ulaşım altyapı sistemlerinin optimize edilmesinde etkili olmuştur [19].

YSA'ların tarihsel gelişimi, genetik algoritmalar kullanarak sinir ağlarının yapay evrimini içeren ve karmaşık takviyeli öğrenme görevlerinde umut vaat eden nöroevrimin ortaya çıkışına da tanık olmuştur [24]. Ek olarak, YSA'ların evrimsel algoritmalarla kombinasyonu, sinir ağlarının öğrenme gücünü ve evrimsel algoritmaların uyarlanabilir yeteneklerini kullanan Evrimsel Yapay Sinir Ağlarının (EANN) geliştirilmesine yol açmıştır [25].

Sonuç olarak, YSA'ların tarihi, McCulloch ve Pitts'in temel çalışmalarından, karmaşık problemlerin çözümünde uyarlanabilirliklerini ve faydalarını gösteren çeşitli alanlardaki yaygın uygulamalarına kadar evrimleriyle karakterize edilir.

Rüzgar hızını tahmin etmek için çeşitli çalışmalarda dalgacık paket ayırıştırması, çoklu çözünürlük analizi, ikincil ayırıştırma algoritması ve fraktal gösterim gibi farklı tekniklerle birlikte yapay sinir ağları (YSA) kullanılmıştır. Bu çalışmalar YSA'ların rüzgar hızı tahminindeki etkinliğini göstermiştir [26] - [45]. Örneğin, [26] ve [27] rüzgar hızı tahmini için YSA'larla birlikte dalgacık ve çoklu çözünürlük analizi kullanmıştır. Ayrıca, Tian ve arkadaşları, rüzgâr hızı tahmini için Elman sinir ağları ile ikincil bir ayırıştırma algoritması kullanmıştır [28]. Ayrıca, D. Petković ve arkadaşları, fraktal enterpolasyona dayalı YSA'lar ve farklı eğitim algoritmaları kullanarak rüzgar hızı dalgalanmasını tahmin etmiştir [32]. Bu çalışmalar, YSA'ların rüzgar hızı tahminindeki çeşitli uygulamalarını toplu olarak vurgulamakta ve çeşitli metodolojilere ve algoritmalara uyarlanabilirliklerini göstermektedir.

Ayrıca, rüzgar hızı tahmini için uzun kısa süreli bellek (LSTM, Long Short-Term Memory), tek boyutlu evrimli sinir ağı (1D-CNN, One Dimensional Convolutional Neural Networks) ve karmaşık değerli sinir ağı (CVNN, Complex-Valued Neural Network) gibi gelişmiş YSA modellerinin kullanımı önerilmiştir [38] [39]. Örneğin, Fukuoka ve arkadaşları, LSTM ve 1D-CNN kullanarak bir rüzgar hızı tahmin modeli önermiş ve rüzgar hızı verilerinin karmaşıklığını yakalamada gelişmiş YSA mimarilerinin potansiyelini göstermiştir [39]. Ayrıca, Komamizu ve arkadaşları, CVNN kullanarak rüzgar enerjisi üretimi için bir tahmin sistemi sunmuş ve YSA'ların yenilenebilir enerji tahminindeki uygulamasını daha da genişletmiştir [38].

Ayrıca, YSA'ların kısa vadeli rüzgar hızı tahminindeki etkinliği çeşitli çalışmalarda vurgulanmıştır [34] [41]. Önerilen bir sinir ağı modeli kullanılarak rüzgar hızının gerçek zamanlı olarak başarılı bir şekilde tahmin edildiğini göstermiştir [34]. Benzer şekilde, Kumar ve arkadaşları, YSA modellerinin hassas kısa vadeli rüzgar hızı tahmini için duyarlılığını vurgulamıştır [41].

Sonuç olarak, literatür, YSA'ların rüzgar hızı tahminindeki uygulamalarının kapsamlı bir incelemesini sunmakta, farklı metodolojiler ve algoritmalarla entegre olma konusundaki çok yönlülüklerini ve rüzgar hızı verilerinin karmaşıklıklarını yakalama potansiyellerini göstermektedir.

## 2.4. Veri Ayırıştırma

Veri ayırıştırma, karmaşık verileri daha basit ve yönetilebilir bileşenlere ayıran bir tekniktir. Verileri, daha sonra bağımsız olarak analiz edilebilecek veya işlenebilecek kurucu parçalara veya alt gruplara ayırmayı içerir. Veri ayırıştırma, sayısal, sinyal ve hatta metinsel veriler dahil olmak üzere çeşitli veri türlerine uygulanabilir.

Veri ayırıştırmanın yaygın uygulamalarından biri sinyal işlemedir. Sinyal işlemede, çok boyutlu sinyallerden anlamlı bilgiler çıkarmak için tensör ayırıştırma teknikleri kullanılır [46]. Tensör ayırıştırma, kanonik korelasyon ve alt uzay teknikleri, sinyal ayırma, doğrusal regresyon, özellik çıkarma ve sınıflandırma gibi yaygın olarak kullanılan sinyal işleme tekniklerinin geliştirilmesini sağlar [46]. Sinyalin kendisini oluşturan bileşenlere ayırıştırılması, verilerin analiz edilmesini ve yorumlanmasını kolaylaştırır.

Veri ayırıştırma, aykırı değer tespitinde de kullanılmaktadır. Bu bağlamda veri, K-ortalama kümeleme gibi kümeleme algoritmaları kullanılarak alt gruplara ayırıştırılır [47]. Olası aykırı değerler, verilerin homojen alt gruplara ayırıştırılmasıyla izole edilebilir ve tespit edilebilir. Bu ayırıştırma yaklaşımı, veri örüntülerinin karmaşıklığını azaltmaya yardımcı olur ve aykırı değer tespitinin doğruluğunu artırır [47].

Veri ayırıştırmanın bir başka uygulaması da veri analizi ve kümelemedir. Çok boyutlu ayırıştırma, Tucker ayırıştırması ve yüksek dereceli tekil değer ayırıştırması gibi farklı kümeleme yöntemleri, verilerdeki örüntüleri ve yapıları tanımlamak için veri ayırıştırmasına dayanır [48]. Bu yöntemler, verileri çekirdek tensörlere ve eş matrislere ayırıştırarak büyük veri kümelerini etkili bir şekilde analiz edebilir ve kümeleyebilir [48].

Veri ayırıştırma, hesaplamalı akışkanlar dinamiği ve görüntü işlemede de kullanılmaktadır. Hesaplamalı akışkanlar dinamiğinde, akışkan akış modellerini analiz etmek ve modellemek için Uygun Ortogonal Ayırıştırma (POD, Proper Orthogonal Decomposition) gibi veri ayırıştırma teknikleri kullanılır [49]. Görüntü işlemede, veri ayırıştırma yöntemleri dört kutuplu verilerdeki farklı saçılma katkılarını ayırır [50].

Genel olarak, veri ayırıştırma karmaşık verileri basitleştirmek ve analiz, işleme ve yorumlamayı kolaylaştırmak için yapılır. Veriyi kendisini oluşturan bileşenlere veya alt gruplara ayırmak, veri içindeki örüntüleri, aykırı değerleri ve yapıları belirlemeyi kolaylaştırır. Veri ayırıştırma teknikleri, sinyal işleme, aykırı değer tespiti, veri analizi ve görüntü işleme gibi çeşitli alanlarda yaygın olarak kullanılmaktadır.

### 2.4.1. Ampirik Mod Ayırıştırma (EMD, Empirical Mode Decomposition)

Ampirik Mod Ayırıştırma (EMD), durağan olmayan sinyal işlemede yaygın olarak kullanılan bir sinyal ayırıştırma yöntemidir [51]. Yöntem, verilen bir sinyali bir dizi İçsel Mod Fonksiyonuna (IMF, Intrinsic Mode Function) ayırıştırır [52], bu da özellikleri çıkarmak ve farklı alanlardaki hataları tespit etmek için daha fazla işlenebilir. Bununla birlikte, EMD yöntemi çeşitli sorunlarla ilişkilidir. İlk sorun, birden fazla frekans bileşeni tek bir IMF'ye karıştığında ortaya çıkan mod karışımıdır. İkinci sorun ise yüksek frekans aralığında ortaya çıkabilen artık gürültüdür [54]. Bu sorunları çözmek için EMD'nin farklı versiyonları önerilmiştir. Popüler versiyonlardan biri, ayırıştırma öncesi sinyale beyaz gürültü ekleyen Topluluk Ampirik Mod Ayırıştırması (EEMD, Ensemble Empirical Mode Decomposition)'dır [52][57]. EMD'nin bir başka versiyonu ise sinyali çift ve tek simetri bileşenlerine ayıran ve her biri EEMD tarafından bağımsız olarak ele alınan Tamamlayıcı EEMD'dir (CEEMD, Complementary Ensemble Empirical Mode Decomposition) [52]. Uyarlanabilir Gürültülü Tam EEMD (CEEMDAN, Complete Ensemble Empirical Mode Decomposition with Adaptive Noise), ayırıştırma öncesi sinyale uyarlanabilir şekilde beyaz gürültü ekleyen EMD tabanlı başka bir algoritmadır [52].

Ayrıca, EMD'nin farklı modifiye edilmiş versiyonları da önerilmiştir. Bunlardan biri, hasar yataklarının özelliklerini temsil eden en uygun IMF'leri seçmek için ağgözlü bir algoritma kullanan Çabuk Ampirik Mod Ayırıştırma (GEMD, Greedy Empirical Mode Decomposition)'dır [55]. EMD'nin bir başka değiştirilmiş versiyonu, gemi yayılan gürültü sinyalinin yüksek frekanslı gürültüsünü etkili bir şekilde bastırmak için aralık eşikleme ve dağılım entropisini içeren Modifiye CEEMDAN'dır [52].

EMD ayrıca farklı sinyallerin özelliklerini çıkarmak için de kullanılır. EMD, Epilepsi Elektroensefalogram (EEG) sinyal işlemede, sinyallerinin istatistiksel özelliklerini çıkarmak için kullanılır [53][60]. Sismik veri işlemede, EMD gibi ayırıştırma tabanlı yöntemler, gürültülü sismik verilerin bir dizi bileşene ayırıştırıldığı gürültü bastırma için yaygın olarak kullanılır [58]. EMD aynı zamanda gürültülü kaotik sinyali katkı gürültüsü üzerinde gürültü etkisini azaltmak için geçerli bir yöntem sağlar [54]. Güç Kalitesi Bozukluğu tanımlamasında, güç kalitesi bozukluğunu tespit etmek için EEMD ve Teager Enerji Operatörü'nden (TEO, Teager Energy Operator) elde edilen anlık genlik ve frekans kullanılır [57]. Ek olarak, EMD, Elektrokardiyografi (EKG) sinyal işleme için sahada programlanabilir kapı dizisi (FPGA, Field Programmable Gate Array) uygulamalarını geliştirmek için kullanılır [56]. Son olarak, EMD ve EEMD ve Yerel Ortalama Ayırıştırma (LMD, Local Mean Decomposition) gibi uzantıları, kızak fide toplama mekanizması hata tanımlaması için BP-AdaBoost optimizasyon algoritmalarına entegre edilmiştir [59].

Sonuç olarak EMD, durağan olmayan sinyalleri IMF'lere ayırtmak için kullanılabilen uyarlanabilir bir sinyal işleme yöntemidir. EEMD ve CEEMDAN dahil olmak üzere EMD'nin çeşitli versiyonları, mod karıştırma ve artık gürültü ile ilgili sorunları çözmek için önerilmiştir. GEMD ve Modifiye CEEMDAN gibi EMD'nin modifiye edilmiş versiyonları, gürültü bastırma ve yüksek frekanslı gürültü giderme için diğer etkili yöntemlerdir. EMD ayrıca epilepsi EEG sinyalleri, sismik veri işleme, kaotik sinyal denoising ve güç kalitesi bozukluğu tanımlama gibi çeşitli alanlarda özellik çıkarma ve teşhis için de kullanılır. Bu çalışmada, Ampirik Mod Ayırma yöntemi türevlerinden popüler olan EEMD ve CEEMDAN yöntemleri, çalışmamızın uygulama kısmında kullanılan veri ayırma metodlarından ikisini teşkil etmektedir.

#### 2.4.2. Yerel Ortalama Ayırma (LMD, Local Mean Decomposition)

Yerel ortalama ayırma (LMD), bir sinyali yerel ortalama bileşenlerine ayırtan bir sinyal işleme yöntemidir [2]. İklim verileri [61], rüzgar hızı verileri [62], titreşim sinyalleri [63], arıza teşhisi [64][66]-[70], dalga denklemleri [65] ve maliyet zaman serisi verileri [69] dahil olmak üzere çeşitli sinyal türlerini analiz etmek ve işlemek için kullanılan bir tekniktir.

LMD genellikle ampirik mod ayırmasına (EMD) alternatif olarak kullanılır [64][66]-[70]. EMD, mod karıştırma ve zarf hataları gibi sınırlamalardan muzdaripken, LMD bu sorunların üstesinden gelir ve arıza teşhisi ve sinyal ayırma açısından daha iyi performans sağlar [66][68]. LMD daha az uç etkisi, daha az iterasyon ve daha doğru sonuçlar gibi avantajlara sahiptir [66].

LMD süreci, yerel ortalamanın orijinal sinyalden iteratif olarak çıkarılmasıyla bir sinyalin yerel ortalama bileşenlerine ayrıştırılmasını içerir [66]. Bu ayırma, farklı frekans bileşenlerinin çıkarılmasına ve sinyaldeki varyasyona katkıda bulunan yerel ölçekli faktörlerin analiz edilmesine olanak tanır [61]. Ahşap ayırma durumunda, LMD yerel ölçekli faktörlerin varyasyonun önemli bir kısmını açıkladığını, iklim faktörlerinin ise sadece daha küçük bir kısmını açıkladığını ortaya koymuştur [61].

LMD, rüzgar hızı tahmini [62], mekanik arıza teşhisi [63][64][66]-[68][70], dalga denklemi çözme [65] ve maliyet tahmini [69] gibi çeşitli alanlarda uygulanmıştır. Rüzgar hızı tahmininde LMD, durağan olmamanın tahmin sonuçları üzerindeki etkisini azaltmak için bir veri ön işleme yöntemi olarak kullanılır [62]. Mekanik arıza teşhisinde, LMD titreşim sinyallerini analiz etmek ve arıza özellik bilgilerini çıkarmak için kullanılır [63][64][66]-[68][70]. Dalga denklemi çözümünde LMD, yerel kesirli dalga denklemlerini çözmek için bir ayırma yöntemi olarak kullanılır [65]. Maliyet tahmininde, LMD maliyet zaman serisi verilerini tahmin için bileşenlere ayırmak için kullanılır [69].

Genel olarak LMD, bir sinyali yerel ortalama bileşenlerine ayıran, yerel ölçekli faktörlerin analizine ve farklı frekans bileşenlerinin çıkarılmasına olanak tanıyan bir sinyal işleme yöntemidir. İklim analizi, rüzgar hızı tahmini, mekanik arıza teşhisi, dalga denklemi çözme ve maliyet tahmini gibi çeşitli alanlarda uygulanmıştır. LMD, Ampirik Mod Ayırma ve Varyasyonel Mod Ayırma gibi ayırma yöntemlerine göre doğruluk ve performans açısından avantajlar sunmaktadır.

#### 2.4.3. Varyasyonel Mod Ayırma (VMD, Variational Mode Decomposition)

Varyasyonel mod ayırma (VMD), verilen bir sinyali birkaç anlamlı moda ayırtmayı amaçlayan bir sinyal ayırma yöntemidir [71]. Dragomiretskiy ve Zosso tarafından 2014 yılında önerilmiştir [75]. VMD, ampirik mod ayırma (EMD) algoritmasının bir geliştirmesidir ve tam matematiksel prensiplere dayanmaktadır [77].

VMD algoritması bir sinyali bant sınırlı alt sinyaller veya modlar topluluğuna ayırtır [75]. Her mod, sınırlı bant genişliği ve daha az spektral örtüşme ile kendi frekansı etrafında merkezlenir [76]. Ayırma, belirli bant genişliği fonksiyonlarına sahip birkaç mod elde etmek için modal fonksiyonu ve merkez frekansı sürekli güncelleyerek, varyasyonel modun optimal çözümünü iteratif olarak arayarak elde edilir [77].

VMD, arıza teşhisi, sinyal analizi ve özellik çıkarımı dahil olmak üzere çeşitli alanlarda uygulanmıştır. Örneğin, yapısal sağlık izlemede, rulmanlı yatakların arıza teşhisinde ve yüksek gerilim devre kesicilerinin arıza teşhisi için kullanılmıştır [73][74]. Astronomi ve astrofizik alanında VMD, güneş atmosferindeki rastgele süreçlerin analizi için kullanılmıştır [72]. Biyomedikal mühendisliği alanında VMD, elektromiyografi (EMG) sinyallerine dayalı el hareketi tanıma için kullanılmıştır [76].

Diğer sinyal ayırma yöntemleriyle karşılaştırıldığında VMD'nin çeşitli avantajları vardır. Uyarlanabilir ve özinelemesizdir, sinyallerin sonlu sayıda içsel modal bileşene ayrıştırılmasına izin verir [78]. VMD ayrıca iyi bir gürültü sağlamlığına sahiptir ve karmaşık bileşenlere sahip durağan olmayan sinyalleri etkili bir şekilde işleyebilir [79]. Ampirik mod ayırması gibi diğer yöntemlere kıyasla daha iyi doğruluğa ve daha yüksek verimliliğe sahip olduğu gösterilmiştir [73].

Özetle, VMD, verilen bir sinyali birkaç anlamlı moda ayırtan bir sinyal ayırma yöntemidir. EMD algoritmasının bir geliştirmesidir ve arıza teşhisi, sinyal analizi ve özellik çıkarımı için çeşitli alanlarda uygulanmıştır. VMD, uyarlanabilirlik, tekrarsızlık ve iyi gürültü sağlamlığı gibi avantajlara sahiptir. Karmaşık bileşenlere sahip durağan olmayan sinyallerin işlenmesinde etkili olduğu gösterilmiştir.

### 3. Uygulama

2020 yılına ait meteorolojik veriler kullanılarak oluşturulan veri setlerinden, mevsimsel farklılıkları gözlemleyebilmek için Ocak, Nisan, Temmuz ve Ekim ayları uygulama için seçilmiştir. Bu ayların ilk haftalarına ait 10 dakika çözünürlüklü verilerden 1008 adet olacak şekilde seçilen veri setleri, ilgili ayların ilk günlerine ait 40m yükseklikteki rüzgar hızlarının 10 dakika aralıkla 24 saat boyunca (144 tahmin noktası için) tahminlemesi için kullanılmıştır.

Bir X zaman noktası için geriye doğru 6 adet (1 saatlik) basınç, sıcaklık ve nem verisi ve X zaman noktasının rüzgar hızı verisi ile eğitilen sinir ağı, basınç, sıcaklık ve nem verisinin 1 adım (10 dakika ileriye) ötelenmesi ile elde edilen giriş verisinin sinir ağına uygulanması ile X+1 zaman noktasına ait rüzgar hızının tahminlenmiştir. Bu işlem 144 kez tekrarlanarak 24 saatlik tahmin verisi elde edilmiştir.

Yukarıda belirtilen tahmin yöntemi ile elde edilen veriler, basınç, sıcaklık ve nem verisinin CEEMDAN, EEMD, LMD ve VMD yöntemleri ayrı ayrı ayrıştırılması ile elde edilen verilerin yine aynı yöntem kullanılarak yapılan 24 saat periyotlu tahminlerin sonuçları ile karşılaştırılmıştır. Performans kriteri olarak Karesel Ortalama Hata (MSE, Mean Square Error) ve Hataların Karesinin Ortalamasının Karekökü (RMSE, Root Mean Squared Error) değerleri kullanılmıştır.

Sinir ağı yapısından klasik sinir ağı aktivasyon fonksiyonları olan tanjant sigmoid (TANSIG, Tangent sigmoid function), logaritmik sigmoid (LOGSIG, Log-Sigmoid function) ve (PURELIN, Linear function) kullanılmış, sinir ağı mimarisinden (4 + 2) olacak şekilde iki gizli katmanlı 6 nöronlu mimari tercih edilmiştir. Tüm uygulamalarda mimari yapı değiştirilmeden kullanılmıştır. Nöron aktivasyon fonksiyonları da tek tip olacak şekilde seçilmiştir.

### 4. Bulgular

**Tablo 1. 1 Ocak 2020 tarihi için 40m yükseklikteki rüzgar hızı tahminleri hata oranları.**

Aktivasyon Fonksiyonu	Veri Ayrıştırmasız		CEEMDAN		EEMD		LMD		VMD	
	MSE	RMSE	MSE	RMSE	MSE	RMSE	MSE	RMSE	MSE	RMSE
LOGSIG	0.0115	0.1070	0.0074	0.0859	0.0077	0.0878	0.0076	0.0873	0.0063	0.0795
PURELIN	0.0995	0.3155	0.0203	0.1424	0.0251	0.1584	0.0462	0.2149	0.0106	0.1028
TANSIG	0.0104	0.1021	0.0049	0.0698	0.0083	0.0914	0.0067	0.0819	0.0077	0.0875

**Tablo 2. 1 Nisan 2020 tarihi için 40m yükseklikteki rüzgar hızı tahminleri hata oranları.**

Aktivasyon Fonksiyonu	Veri Ayrıştırmasız		CEEMDAN		EEMD		LMD		VMD	
	MSE	RMSE	MSE	RMSE	MSE	RMSE	MSE	RMSE	MSE	RMSE
LOGSIG	0.0133	0.1154	0.0081	0.0897	0.0121	0.1099	0.0089	0.0944	0.0080	0.0896
PURELIN	0.0690	0.2626	0.0204	0.1430	0.0309	0.1756	0.0281	0.1676	0.0189	0.1377
TANSIG	0.0107	0.1036	0.0070	0.0836	0.0090	0.0948	0.0097	0.0985	0.0083	0.0913

**Tablo 3. 1 Temmuz 2020 tarihi için 40m yükseklikteki rüzgar hızı tahminleri hata oranları.**

Aktivasyon Fonksiyonu	Veri Ayrıştırmasız		CEEMDAN		EEMD		LMD		VMD	
	MSE	RMSE	MSE	RMSE	MSE	RMSE	MSE	RMSE	MSE	RMSE
LOGSIG	0.0069	0.0833	0.0050	0.0708	0.0067	0.0816	0.0053	0.0726	0.0046	0.0682
PURELIN	0.0455	0.2133	0.0136	0.1165	0.0195	0.1395	0.0197	0.1403	0.0117	0.1080
TANSIG	0.0077	0.0875	0.0066	0.0812	0.0068	0.0826	0.0052	0.0724	0.0065	0.0805

**Tablo 4. 1 Ekim 2020 tarihi için 40m yükseklikteki rüzgar hızı tahminleri hata oranları.**

Aktivasyon Fonksiyonu	Veri Ayrıştırmasız		CEEMDAN		EEMD		LMD		VMD	
	MSE	RMSE	MSE	RMSE	MSE	RMSE	MSE	RMSE	MSE	RMSE
LOGSIG	0.0047	0.0683	0.0019	0.0442	0.0025	0.0504	0.0043	0.0652	0.0032	0.0565
PURELIN	0.0143	0.1195	0.0028	0.0534	0.0029	0.0536	0.0039	0.0623	0.0040	0.0635
TANSIG	0.0050	0.0708	0.0028	0.0527	0.0049	0.0698	0.0042	0.0646	0.0027	0.0523

Ocak, Nisan Temmuz ve Ekim aylarına ait yapılan 40m yükseklik için 24 saat süreli 10 dakika aralıklı rüzgar hızı tahmini sonuçlarına ait MSE ve RMSE hata değerlerinin bulunduğu tablolar (Tablo 1, Tablo 2, Tablo 3, Tablo 4) yukarıda verilmiştir.

Elde edilen bulgular göstermektedir ki, uygulanan veri ayrıştırma yöntemi ne olursa olsun, veri ayrıştırmalı dataların giriş sağladığı sinir ağlarının tahmin performansları her durumda veri ayrıştırmasız yapılan tahminlerden daha iyi sonuç vermektedir.

Özellikle bir genellemeden kaçınarak, CEEMDAN ve VMD veri ayrıştırma yöntemleri ile yapılan tahminlerin daha ön planda olduğu gözlenmektedir. Bu yaklaşımdan kastımız, değişen veri yapıları ile ayrıştırma yöntemlerinin başarımlarının değişiklik gösterme olasılığı bulunmasıdır.. Ancak meteorolojik veriler ile yapılan rüzgar hızı tahmininde CEEMDAN ve VMD veri ayrıştırma yöntemlerinin belirgin bir yüksek performans sağladığı söylenebilir.

## 5. Sonuçlar

Ampirik mod ayrıştırması türevleri (EEMD - CEEMDAN), Yerel Ortalama Ayrıştırması (LMD) ve Varyasyonel Mod Ayrıştırması gibi veri ayrıştırma tekniklerinin kullanımı rüzgar hızı tahmininde yapay sinir ağlarının tahmin performansı üzerinde olumlu bir etkiye sahiptir. Bu teknikler, düzensiz dalgalanmaların ve veri dalgalanmalarının etkisini etkili bir şekilde azaltarak daha doğru ve güvenilir tahminler yapılmasını sağlar. Ayrıca, rüzgar hızı verilerinin ayrıştırılması, yapay sinir ağlarının çok ölçekli ve zamansal bilgileri yakalama yeteneğini artırarak önemli özelliklerin ve modellerin çıkarılmasını sağlar. Bu da sonuçta tahmin doğruluğunun ve performansının artmasını sağlar. Bu nedenle, veri ayrıştırma teknikleri, rüzgar hızı tahmininde yapay sinir ağlarının tahmin performansını artırmada çok önemli bir rol oynamaktadır.

## Referanslar

- [1] G. Lee., Y. Ding., M. Genton. and L. Xie. "Power curve estimation with multivariate environmental factors for inland and offshore wind farms". *Journal of the American Statistical Association*. vol. 110. no. 509. p. 56-67. 2015.
- [2] Y. Hadri., V. Khokhlov. and M. Slizhe. "Regional climate models projections of wind speed in Morocco for period 2020-2050". *Asian Journal of Environment & Ecology*. vol. 6. no. 3. p. 1-7. 2018.
- [3] E. Chiodo., M. Fantauzzi. and G. Mazzanti. "The compound inverse Rayleigh as an extreme wind speed distribution and its bayes estimation". *Energies*. vol. 15. no. 3. p. 861. 2022.
- [4] L. Herbst and J. Lalk. "A case study of climate variability effects on wind resources in South Africa". *Journal of Energy in Southern Africa*. vol. 25. no. 3. p. 2-10. 2014.
- [5] Z. Rajab., Y. Sassi., A. Taher., A. Khalil. and F. Mohamed. "A practical seasonal performance evaluation of small wind turbine in urban environment". *Wind Engineering*. vol. 43. no. 4. p. 344-358. 2019.
- [6] L. Rapella., D. Faranda. and M. Gaetani. "Climate change on extreme winds already affects wind energy availability in Europe". *EGU General Assembly 2022, Vienna, Austria, 23–27 May 2022, EGU22-9634*. 2022.
- [7] G. Fajardo-Pulido and G. Fuster-Lopez. " Preliminary study of wind speed characterization to install a 400 W wind turbine ". *Ecorfan Journal Republic of Paraguay*. p. 23-30. 2019.
- [8] L. Rapella., D. Faranda., M. Gaetani., D. Philippe. and M. Ginesta. "Climate change on extreme winds already affects off-shore wind power availability in Europe". *Environmental Research Letters*. vol. 18. no. 3. p. 034040. 2023.
- [9] N. Saeid and M. Seyed. "Choose suitable wind turbines for Manjil wind power plant using Monte Carlo simulation". *International Journal of Computer Applications*. vol. 15. no. 1. p. 26-34. 2011.
- [10] J. Salmon and P. Taylor. "Errors and uncertainties associated with missing wind data and short records". *Wind Energy*. vol. 17. no. 7. p. 1111-1118. 2013.
- [11] K. Chatfield., K. Simonyan., A. Vedaldi. and A. Zisserman. "Return of the devil in the details: delving deep into convolutional nets". *The British Machine Vision Association*. 2014.
- [12] P. Gouverneur., F. Li., W. Adamczyk., T. Szikszay., K. Luedtke. and M. Grzegorzec. "Comparison of feature extraction methods for physiological signals for heat-based pain recognition". *Sensors*. vol. 21. no. 14. p. 4838. 2021.
- [13] A. Pamuncak., M. Salami., A. Adha., B. Budiono. and I. Laory. "Estimation of structural response using convolutional neural network: application to the Suramadu Bridge". *Engineering Computations*. vol. 38. no. 10. p. 4047-4065. 2021.
- [14] D. Cusumano., G. Meijer., J. Lenkovicz., G. Chiloiro., L. Boldrini., C. Masciocchi., N. Dinapoli., R. Gatta., C. Casà., A. Damiani., B. Barbaro., M. Gambacorta., L. Azario., M. De Spirito., M. Intven. and V. Valentini. "A field strength

independent MR radiomics model to predict pathological complete response in locally advanced rectal cancer". *La Radiologia Medica*. vol. 126. no. 3. p. 421-429. 2020.

- [15] W. Park and J. Park. "History and application of artificial neural networks in dentistry". *European Journal of Dentistry*. vol. 12. no. 04. p. 594-601. 2018.
- [16] G. Parapuram. M. Mokhtari. and J. Hmida. "An artificially intelligent technique to generate synthetic geomechanical well logs for the bakken formation". *Energies*. vol. 11. no. 3. p. 680. 2018.
- [17] I. Farkhoutdinov. "The use of artificial neural networks to solve the "make or buy" problem". *Helix*. vol. 9. no. 4. p. 5243-5247. 2019.
- [18] G. Zhou., Y. Ji., X. Chen., and F. Zhang. "Artificial neural networks and the mass appraisal of real estate". *International Journal of Online Engineering (Ijoe)*. vol. 14. no. 03. p. 180. 2018.
- [19] K. Gharehbaghi. "Artificial neural network for transportation infrastructure systems". *Matec Web of Conferences*. vol. 81. p. 05001. 2016.
- [20] S. Fard. "Solving universal approximation problem by hankel approximate identity neural networks in function spaces". *The fourth International Conference on Information Science and Cloud Computing (ISCC2015)*. p. 31. 2016.
- [21] N. Ganesan., K. Venkatesh., M. Rama., and A. Palani. "Application of neural networks in diagnosing cancer disease using demographic data". *International Journal of Computer Applications*. vol. 1. no. 26. p. 81-97. 2010.
- [22] R. Suryanita., H. Maizir., E. Yuniarto., M. Zulfakar. and H. Jingga. "Damage level prediction of reinforced concrete building based on earthquake time history using artificial neural network". *Matec Web of Conferences*. vol. 138. p. 02024. 2017.
- [23] Y. Yang., B. Yang., and C. Su. "Application of residual shear strength predicted by artificial neural network model for evaluating liquefaction-induced lateral spreading". *Advances in Civil Engineering*. vol. 2020. p. 1-15. 2020.
- [24] K. Stanley and R. Miikkulainen. "Evolving neural networks through augmenting topologies". *Evolutionary Computation*. vol. 10. no. 2. p. 99-127. 2002.
- [25] J. Ortiz-Rodriguez., M. Martinez-Blanco., E. Gallego. and H. Vega-Carrillo. "A computational tool design for evolutionary artificial neural networks in neutron spectrometry and dosimetry". *Electronics, Robotics and Automotive Mechanics Conference*. p. 113-118. 2009.
- [26] H. Liu., H. Tian., D. Pan., and Y. Li. "Forecasting models for wind speed using wavelet. wavelet packet. time series and artificial neural networks". *Applied Energy*. vol. 107. p. 191-208. 2013.
- [27] B. Doucoure., K. Agbossou. and A. Cardenas. "Time series prediction using artificial wavelet neural network and multi-resolution analysis: application to wind speed data". *Renewable Energy*. vol. 92. p. 202-211. 2016.
- [28] H. Tian., X. Liang. and H. Liu. "Wind speed forecasting approach using secondary decomposition algorithm and Elman neural networks". *Applied Energy*. vol. 157. p. 183-194. 2015.
- [29] M. Bilgili., B. Şahin. and A. Yaşar. "Application of artificial neural networks for the wind speed prediction of target station using reference stations data". *Renewable Energy*. vol. 32. no. 14. p. 2350-2360. 2007.
- [30] P. Ramasamy., S. Chandel. and A. Yadav. "Wind speed prediction in the mountainous region of India using an artificial neural network model". *Renewable Energy*. vol. 80. p. 338-347. 2015.
- [31] S. Salcedo-Sanz., Á. Pérez-Bellido., E. Ortiz-García., A. Portilla-Figueras., L. Prieto. and D. Paredes. "Hybridizing the fifth generation mesoscale model with artificial neural networks for short-term wind speed prediction". *Renewable Energy*. vol. 34. no. 6. p. 1451-1457. 2009.
- [32] D. Petković., V. Nikolić., V. Mitić. and L. Kocić. "Estimation of fractal representation of wind speed fluctuation by artificial neural network with different training algorithms". *Flow Measurement and Instrumentation*. vol. 54. p. 172-176. 2017.



- [33] T. Blanchard and B. Samanta. "Wind speed forecasting using neural networks". *Wind Engineering*. vol. 44. no. 1. p. 33-48. 2019.
- [34] A. Lodge and X. Yu. "Short term wind speed prediction using artificial neural networks". *International Conference on Information Science and Technology (ICIST)*. p. 539-542. 2014.
- [35] Ü. Filik and T. Filik. "Wind speed prediction using artificial neural networks based on multiple local measurements in Eskisehir". *Energy Procedia*. vol. 107. p. 264-269. 2017.
- [36] G. Kariniotakis., G. Stavrakakis. and E. Nogaret. "Wind power forecasting using advanced neural networks models". *Ieee Transactions on Energy Conversion*. vol. 11. no. 4. p. 762-767. 1996.
- [37] F. Gemici and A. Şahin. "Estimation of wind speed with artificial neural networks method for isparta using meteorological measurement data". *International Journal of Energy Applications and Technologies*. vol. 8. no. 2. p. 65-69. 2021.
- [38] T. Komamizu., T. Yasuno. and H. Sori. "Study on output prediction system of wind power generation using complex-valued neural network with multipoint GPV data". *Ieej Transactions on Electrical and Electronic Engineering*. vol. 8. no. 1. p. 33-39. 2012.
- [39] R. Fukuoka., H. Suzuki., T. Komamizu., A. Kuwahara. and T. Yasuno. "Wind speed prediction model using LSTM and 1D-CNN". *Journal of Signal Processing*. vol. 22. no. 4. p. 207-210. 2018.
- [40] G. Shigute and J. Li. "A wind speed estimation method for quadcopter using artificial neural network". *International Journal of Engineering Research And*. vol. V8. no. 04. 2019.
- [41] A. Kumar., T. Cermak. and S. Misak. "Short-term wind power plant predicting with artificial neural network". *International Scientific Conference on Electric Power Engineering (EPE)*. p. 584-588. 2015.
- [42] M. Zhao., D. Jiang. and C. Liu. "Research on wind power forecasting method using phase space reconstruction and artificial neural network". *International Conference on Sustainable Power Generation and Supply, SUPERGEN*. p. 1-5. 2009.
- [43] Z. Zheng., Y. Chen., X. Zhou., M. Huo., B. Zhao. and M. Guo. "Short-term wind power forecasting using empirical mode decomposition and RBFNN". *International Journal of Smart Grid and Clean Energy*. vol. 2. no. 2. p. 192-199. 2013.
- [44] A. Camara., F. Wang. and X. Liu. "Energy consumption forecasting using seasonal arima with artificial neural networks models". *International Journal of Business and Management*. vol. 11. no. 5. p. 231. 2016.
- [45] E. Bezerra., R. Leao. and A. Braga. "A self-adaptive approach for particle swarm optimization applied to wind speed forecasting". *Journal of Control Automation and Electrical Systems*. vol. 28. no. 6. p. 785-795. 2017.
- [46] A. Cichocki., D. Mandic., A. Phan., G. Zhou., Q. Zhao., C. Caiafa. and H. Phan. "Tensor decompositions for signal processing applications: from two-way to multiway component analysis". *Ieee Signal Processing Magazine*. vol. 32. no. 2. p. 145-163. 2015.
- [47] G. Duari and R. Kumar. "Data decomposition for outlier detection". 2023. <https://doi.org/10.21203/rs.3.rs-2565842/v1>
- [48] H. Zhang., P. Li., H. Ye., D. Shi., Z. Xue., W. Fan. and F. Meng. "Data distribution and tensor influence analysis of different clustering methods". 2023. <https://doi.org/10.21203/rs.3.rs-2754780/v1>
- [49] M. Kalugin and I. Evdokimov. "Numerical study of characteristic modes and frequencies of flow in high-speed compressors". *Proceedings of the Institute for System Programming of Ras*. vol. 29. no. 1. p. 21-38. 2017.
- [50] E. Kwok., C. Li., Q. Zhao. and Y. Li. "A novel two-component decomposition for co-polar channels of gf-3 quad-pol data". *The International Archives of the Photogrammetry Remote Sensing and Spatial Information Sciences*. vol. XLII-3. p. 745-749. 2018.
- [51] G. Singh., G. Kaur. and V. Kumar. "Ecg denoising using adaptive selection of IMFs through EMD and EEMD". 2014 *International Conference on Data Science & Engineering (ICDSE)*. p. 228-231. 2014.

- [52] G. Li., Z. Yang. and H. Yang. "A denoising method of ship radiated noise signal based on modified CEEMDAN, dispersion entropy and interval thresholding". *Electronics*. vol. 8. no. 6. p. 597. 2019.
- [53] S. Saminu., G. Xu., S. Zhang., A. Isselmou., A. Jabire., I. Karaye. and I. Ahmad. "Hybrid Feature Extraction Technique for Multi-Classification of Ictal and Non-Ictal EEG Epilepsy Signals". *Elektrika- Journal of Electrical Engineering*. vol. 19. no. 2. p. 1-11. 2020.
- [54] F. Hasan. "Chaotic signals denoising using empirical mode decomposition inspired by multivariate denoising". *International Journal of Electrical and Computer Engineering (IJECE)*. vol. 10. no. 2. p. 1352. 2020.
- [55] C. Lee., K. Huang., Y. Hsieh. and P. Chen. "Optimal intrinsic mode function based detection of motor bearing damages". *Applied Sciences*. vol. 9. no. 13. p. 2587. 2019.
- [56] D. Fernandes and M. Suchetha. "Field-programmable gate array implementation of empirical mode decomposition algorithm for electrocardiogram processing". *Asian Journal of Pharmaceutical and Clinical Research*. vol. 10. no. 13. p. 77. 2017.
- [57] S. Wang., Q. Liao., D. Liu. Y. Zhou., B. Xu., Y. Wang. and L. Lu. "Identification of power quality disturbances based on EEMD and TEO". *Applied Mechanics and Materials*. vol. 433-435. p. 469-476. 2013. <https://doi.org/10.4028/www.scientific.net/amm.433-435.469>
- [58] P. Bing., W. Liu. and Z. Zhang. "A robust random noise suppression method for seismic data using sparse low-rank estimation in the time-frequency domain". *Ieee Access*. vol. 8. p. 183546-183556. 2020.
- [59] Z. He., Z. Haiyang., J. Wang., X. Jin., S. Gao. and J. Pang. "Bp-adaboost algorithm based on variational mode decomposition optimized by envelope entropy for diagnosing the working conditions of a slideway seedling-picking mechanism". *Applied Engineering in Agriculture*. vol. 37. no. 4. p. 665-675. 2021.
- [60] J. Li., J. Jiang., X. Fan., H. Wang., L. Song., W. Liu., J. Yang. and L. Chen. "A new method for weak fault feature extraction based on improved MED". *Shock and Vibration*. vol. 2018. p. 1-11. 2018.
- [61] M. Bradford., R. Warren., P. Baldrian., T. Crowther., D. Maynard., E. Oldfieldet., W. Wieder., S. Wood. and J. Kind. "Climate fails to predict wood decomposition at regional scales". *Nature Climate Change*. vol. 4. no. 7. p. 625-630. 2014.
- [62] Z. Tian., S. Li. and Y. Wang. "A prediction approach using ensemble empirical mode decomposition-permutation entropy and regularized extreme learning machine for short-term wind speed". *Wind Energy*. vol. 23. no. 2. p. 177-206. 2019.
- [63] N. Huang., H. Chen., G. Cai., L. Fang. and Y. Wang. "Mechanical fault diagnosis of high voltage circuit breakers based on variational mode decomposition and multi-layer classifier". *Sensors*. vol. 16. no. 11. p. 1887. 2016.
- [64] S. Fang., X. Wang. and C. Lu. "Rolling bearing fault diagnosis based on LCD–TEO and multifractal detrended fluctuation analysis". *Mechanical Systems and Signal Processing*. vol. 60-61. p. 273-288. 2015.
- [65] A. Hemedat., E. Eladdad. and I. Lairje. "Local fractional analytical methods for solving wave equations with local fractional derivative". *Mathematical Methods in the Applied Sciences*. 2018.
- [66] H. Li., B. Fan., R. Jia., F. Zhai., L. Bai. and X. Luo. "Research on multi-domain fault diagnosis of gearbox of wind turbine based on adaptive variational mode decomposition and extreme learning machine algorithms". *Energies*. vol. 13. no. 6. p. 1375. 2020.
- [67] S. Barik. "Fault detection and classification of dc microgrid based on vmd". *Compel the International Journal for Computation and Mathematics in Electrical and Electronic Engineering*. vol. 42. no. 2. p. 302-322. 2022.
- [68] M. Bouaicha., M. Guerroum., I. Adraoui., H. Gziri., A. Elmahjoub. and M. Zegrari. "Diagnosis of mechanical faults affecting a hydroelectric group by vibration analysis". *International Journal of Emerging Technology and Advanced Engineering*. vol. 11. no. 11. p. 86-100. 2021.
- [69] Z. Jiang., Z. Ding., Y. Liu., Y. Wang., X. Hu. and Y. Yang. "A data-driven based decomposition–integration method for remanufacturing cost prediction of end-of-life products". *Robotics and Computer-Integrated Manufacturing*. vol. 61. p. 101838. 2020.

- [70] L. Ning., L. Bing., J. Wei. and X. Cungen. "A fault pattern recognition method for rolling bearing based on celmdan and fuzzy entropy". *Journal of Vibroengineering*. vol. 22. no. 6. p. 1326-1337. 2020.
- [71] Z. Wang., N. Yang., N. Li., W. Du. and J. Wang. "A new fault diagnosis method based on adaptive spectrum mode extraction". *Structural Health Monitoring*. vol. 20. no. 6. p. 3354-3370. 2021.
- [72] D. Kolotkov., S. Anfinogentov. and V. Nakariakov. "Empirical mode decomposition analysis of random processes in the solar atmosphere". *Astronomy and Astrophysics*. vol. 592. p. A153. 2016.
- [73] B. Pang., M. Nazari., Z. Sun., J. Li. and G. Tang. "An optimized variational mode extraction method for rolling bearing fault diagnosis". *Structural Health Monitoring*. vol. 21. no. 2. p. 558-570. 2021.
- [74] E. Wang., L. Liu., H. Jia., J. Wang., Y. Xu. and X. Xie. "Fault diagnosis method of high voltage circuit breaker based on the combination of time-frequency multi-characteristics of acoustic signal". *Journal of Vibroengineering*. vol. 25. no. 1. p. 156-170. 2022.
- [75] Y. Guo., S. Jiang., Y. Yang., X. Jin. and Y. Wei. "Gearbox fault diagnosis based on improved variational mode extraction". *Sensors*. vol. 22. no. 5. p. 1779. 2022.
- [76] K. Yang., M. Xu., X. Yang., R. Yang. and Y. Chen. "A novel emg-based hand gesture recognition framework based on multivariate variational mode decomposition". *Sensors*. vol. 21. no. 21. p. 7002. 2021.
- [77] T. Zhang and C. Fu. "Application of improved VMD-LSTM model in sports artificial intelligence". *Computational Intelligence and Neuroscience*. vol. 2022. p. 1-6. 2022.
- [78] H. Peng and M. Zhang. "Application of deep neural network algorithm in speech enhancement of online English learning platform". *Icst Transactions on Scalable Information Systems*. p. e13. 2022.
- [79] H. Li., B. Xu., F. Zhou., B. Yan. & F. Zhou. "Empirical variational mode decomposition based on binary tree algorithm". *Sensors*. vol. 22. no. 13. p. 4961. 2022.