



Kuraklığın Dinamiklerini Çözömllemek: Dalgacık Tabanlı Makine Öğrenmesi Yaklaşımıyla Konya Örneđi

Araştırma Makalesi
10.65520/erciyesfen.1818938

Künye:

Sayı: 42(1)

Yıl: 2026

Sayfa: 372-392

Gülsün Yıldırım^{a*}
 Özlem Terzi^b

^a Doktora Öğr., Isparta Uygulamalı
Bilimler Üniversitesi,
gulsunyildirim98@gmail.com
^b Prof. Dr., Isparta Uygulamalı
Bilimler Üniversitesi,
ozlemterzi@isparta.edu.tr

* Sorumlu Yazar

Geliş Tarihi: 06.11.2025

Kabul Tarihi: 07.04.2026

Atıf:

Gülsün Yıldırım, Özlem Terzi,
(2026). Kuraklığın Dinamiklerini
Çözömllemek: Dalgacık Tabanlı
Makine Öğrenmesi Yaklaşımıyla
Konya Örneđi. *Erciyes University
Journal of Institute Of Science and
Technology*, 42(1), 372-392.
<https://doi.org/10.65520/erciyesfen.1818938>

Öz

Kuraklık, bir bölgenin iklim koşullarını yansıtan ve su mevcudiyetinin uzun süreli olarak düşük seviyelerde seyretmesiyle ortaya çıkan doğal bir çevresel dengesizlik durumudur. Kuraklık olayları; sosyoekonomik yapı, tarımsal üretim ve ekosistemler üzerinde ciddi olumsuz etkiler yaratmaktadır. Ancak bu etkiler, kuraklığın mekânsal ve zamansal dinamiklerinin doğru analiz edilmesi ve önceden tahmin edilmesiyle önemli ölçüde azaltılabilir. Bu çalışmada, Türkiye'nin en kurak bölgelerinden biri olan Konya ilinde meteorolojik kuraklık analizi Keşif Kuraklık İndisi (KKİ) kullanılarak gerçekleştirilmiştir. Bu kapsamda, bölgede yer alan dokuz meteoroloji istasyonuna ait 1985–2021 dönemine ilişkin aylık ortalama sıcaklık verilerinden potansiyel evapotranspirasyon (PET) değerleri hesaplanmış, ardından yağış ve PET verileri kullanılarak KKİ serileri oluşturulmuştur. Hesaplanan KKİ değerleri kullanılarak çeşitli makine öğrenmesi (ML) ve dalgacık tabanlı makine öğrenmesi (D-ML) modelleri geliştirilmiş, elde edilen sonuçlar karşılaştırmalı olarak değerlendirilmiştir. Analizler, D-ML modellerinin kuraklık tahmininde ML modellerine kıyasla daha yüksek doğruluk ve genelleme yeteneğine sahip olduğunu göstermiştir. Ayrıca geliştirilen modellerle elde edilen KKİ serilerinin eğilimleri Mann–Kendall eğilim testiyle incelenmiş ve tüm modellerde istatistiksel olarak anlamlı bir eğilim gözlenmemiştir.

Anahtar kelimeler: Dalgacık Dönüşümü, Makine Öğrenmesi, Kuraklık Tahmini, Keşif Kuraklık İndisi, Mann-Kendall Eğilim Testi, Konya



Unraveling the Dynamics of Drought: Wavelet-Based Machine Learning Approach, the Case of Konya, Türkiye

Abstract

Abstract: Drought is a natural environmental imbalance that reflects the climatic conditions of a region and arises from prolonged periods of low water availability. Drought events have serious adverse impacts on socioeconomic structures, agricultural production, and ecosystems. However, these impacts can be significantly reduced through accurate analysis and prediction of the spatial and temporal dynamics of drought. In this study, meteorological drought analysis was conducted in Konya Province, one of the driest regions of Türkiye, using the Reconnaissance Drought Index (RDI). For this purpose, potential evapotranspiration (PET) values were calculated from the monthly average temperature data of nine meteorological stations in the region for the period 1985–2021, and RDI series were then generated using precipitation and PET data. Various machine learning (ML) and wavelet-based machine learning (W-ML) models were developed using the calculated RDI values, and the results were evaluated

Screened by



Except where otherwise noted, content in this article is licensed under a Creative Commons 4.0 International license. Icons by Font Awesome.

comparatively. The analyses showed that the W-ML models achieved higher accuracy and better generalization ability in drought prediction compared with the ML models. In addition, the trends of the RDI series obtained from the developed models were examined using the Mann-Kendall test, and no statistically significant trend was observed in any of the models.

Keywords: Wavelet Transform, Machine Learning, Drought Prediction, Reconnaissance Drought Index, Mann-Kendall Trend Test, Konya



1. Giriş

Normale göre belirgin bir yağış eksikliği, yüksek buharlaşma oranıyla birleştiğinde kuraklığa yol açar [1], [2]. Kuraklık, dünyanın birçok iklim bölgesinde görülen; ekonomik, toplumsal ve çevresel açıdan ciddi etkiler doğurabilen, doğası gereği yavaş gelişen ancak ani etkiler yaratabilen bir iklim olayıdır [3], [4]. Günümüzde kuraklık olaylarının sıklığı ve şiddeti artmakta, bu durum da insanlığı diğer doğal afetlerden daha fazla etkilemektedir. Kuraklık, doğal çevrenin bir parçası olmakla birlikte uzun süreli su kıtlığına işaret eder [5]. Yüzey ve yeraltı su kaynaklarında azalma, su kalitesinin bozulması, ürün kayıpları ve ekosistem tahribatı gibi sonuçlarla su kıtlığı daha da karmaşık bir hâl almaktadır [6].

Kuraklığın doğasını ve etkilerini anlamak için bu olgunun çok boyutlu yapısının incelenmesi gereklidir. Wilhite ve Glantz [7] kuraklığı dört ana gruba ayırmıştır: meteorolojik, tarımsal, hidrolojik ve sosyo-ekonomik kuraklık. Yağış miktarının uzun dönem ortalamasının altına düşmesiyle başlayan meteorolojik kuraklık, toprak nemindeki azalma yoluyla tarımsal kuraklığa neden olur. Bu durum zamanla yüzey ve yeraltı sularında azalmaya, dolayısıyla hidrolojik kuraklığa yol açar. Su yetersizliği insan yaşamını ve ekonomiyi doğrudan etkilediğinde ise sosyo-ekonomik kuraklık ortaya çıkar [8].

Son yıllarda, yüksek işlem kapasitesine sahip bilgisayar sistemleri sayesinde kuraklık tespit ve tahmininde yapay zekâ ve makine öğrenmesi yöntemleri giderek yaygınlaşmaktadır. Geçmişte insan müdahalesine dayalı karar süreçleri, günümüzde bu yöntemlerle daha hızlı ve doğru şekilde gerçekleştirilebilmektedir [9]. Makine öğrenmesi modellerinin hidrolojik verilerden anlamlı bilgi çıkarabilmesi için gelişmiş veri ön işleme yöntemleri büyük önem taşımaktadır. Bu bağlamda dalgacık dönüşümü, sinyallerin hem zamansal hem de frekans bileşenlerini aynı anda inceleyebilmesi sayesinde öne çıkmaktadır. Özellikle durağan olmayan hidrolojik zaman serilerini farklı ölçeklerde alt bileşenlere ayırarak karmaşık süreçlerin daha tutarlı biçimde modellenmesine olanak tanır. Dalgacık dönüşümünün önemli avantajlarından biri, düşük frekanslarda geniş, yüksek frekanslarda ise dar pencere boyutlarıyla zaman-frekans çözünürlüğünü optimize etmesidir [10].

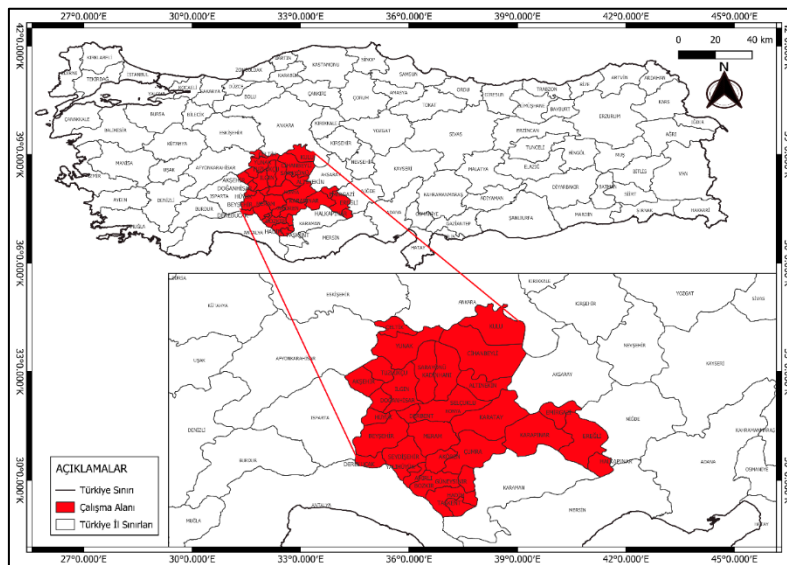
Literatürde dalgacık dönüşümü, makine öğrenmesi ve kuraklık analizi konularında çok sayıda çalışma bulunmaktadır. Asadi Zarch vd. [11], İran'daki 40 meteoroloji istasyonunda farklı zaman ölçeklerinde Standart Yağış İndisi (SYİ) ve Keşif Kuraklık İndisini (KKİ) kullanarak kuraklık analizleri yapmış, potansiyel evapotranspirasyonun (PET) belirleyici etkisi nedeniyle KKİ'nin daha uygun bir gösterge olduğunu belirtmiştir. Zarei vd. [12], 16 istasyondan elde ettikleri 30 yıllık iklim verileriyle mevsimsel kuraklık dağılımlarını KKİ kullanarak değerlendirmiş ve yöntemin tarımsal üretim ve su yönetiminde etkili olduğunu göstermiştir. Merabti vd. [13], Kuzeydoğu Cezayir'deki 3-, 6- ve 12- aylık periyotlarda SYİ ve KKİ'yi karşılaştırmış; PET değişkenini içermesi sayesinde KKİ'nin SYİ'ye göre daha duyarlı sonuçlar verdiğini saptamıştır. Terzi ve Barak [14], Kızılırmak Nehri üzerinde akım tahmini için Yapay Sinir Ağları (YSA) ve Dalgacık-YSA (D-YSA) modellerini karşılaştırmış ve dalgacık dönüşümünün model doğruluğunu artırdığını belirtmiştir. Achite vd. [15], Kuzey Cezayir'de çeşitli makine öğrenmesi algoritmalarını Ayrık Dalgacık Dönüşümü (ADD) ile birleştirerek hibrit modeller geliştirmiş ve bu modellerin tahmin performansının arttığını raporlamıştır. Mokhtar vd. [16], Çin'in

Tibet Platosu'nda çeşitli makine öğrenmesi algoritmalarıyla kuraklık tahmini yapmış, bu algoritmaların karar verme süreçlerinde etkin araçlar olduğunu vurgulamıştır. Tuğrul vd. [17] ise Konya için geliştirdikleri hibrit ADD-DVM modelinin en yüksek tahmin başarısını sağladığını ortaya koymuştur. Bu çalışmalar, KKİ'nin kuraklık tespitinde güçlü bir araç olduğunu ve dalgacık dönüşümünün makine öğrenmesi modellerinin performansını artırarak daha doğru ve genellenebilir tahminler üretilmesine katkı sağladığını göstermektedir. Mevcut literatürde kuraklık tahmini üzerine çok sayıda model geliştirilmiş olmasına karşın, dalgacık tabanlı veri ön işleme yaklaşımının farklı makine öğrenmesi algoritmalarının genelleme başarısı üzerindeki etkisini aynı veri seti üzerinde sistematik olarak karşılaştıran çalışmalar oldukça sınırlıdır. Bu çalışma, farklı öğrenme yapısına sahip algoritmaların dalgacık dönüşümü karşısındaki performans değişimini incelemekte ve model sonuçlarının farklı zaman ölçeklerindeki kararlılığını değerlendirmektedir. Böylece çalışma, yalnızca tahmin başarısını raporlayan bir uygulama olmanın ötesine geçerek, dalgacık dönüşümünün kuraklık modellemesindeki yöntemsel katkısını ortaya koymaktadır. Bu çerçevede, söz konusu yöntemsel katkının somut olarak değerlendirilmesi amacıyla Konya ilinde meteorolojik kuraklıkların KKİ kullanılarak dalgacık tabanlı makine öğrenmesi (D-ML) modelleriyle tahmin edilmesi hedeflenmiştir. Bu kapsamda, dokuz meteoroloji istasyonuna ait yağış ve PET verileriyle 9- ve 12- aylık periyotlarda KKİ değerleri hesaplanmış, bu değerlerle hem klasik ML hem de D-ML modelleri geliştirilmiştir. Son olarak, elde edilen tahmin serileri üzerinde Mann-Kendall eğilim testi uygulanarak kuraklık eğilimleri analiz edilmiştir.

2. Materyal ve Metot

2.1. Çalışma bölgesi ve veriler

Çalışma bölgesi olarak, $36^{\circ}22'$ ve $39^{\circ}08'$ kuzey enlemleri ile $31^{\circ}14'$ ve $34^{\circ}05'$ doğu boylamları arasında yer alan Konya ili seçilmiştir (Şekil 1). Yüzölçümü göller hariç 38.873 km^2 'dir ve bu özelliğiyle Türkiye'nin en geniş yüz ölçümüne sahip ilidir. Ortalama yükseltisi 1.016 m 'dir. Konya ili sınırları içerisinde yer alan akarsuların büyük bölümü mevsimlik ve sel rejimlidir. Bu akarsular kısa boylu olup, kapalı havza yapısı nedeniyle çoğunlukla ova tabanlarında sönümlenir. Akarsular kar ve yağmur sularıyla beslenmekte; ancak düzensiz yağış rejimi, akarsu akımlarında da belirgin düzensizliklere neden olmaktadır [18].



Şekil 1. Çalışma alanı [19]

Çalışmada, Meteoroloji Genel Müdürlüğü'nden 1985–2021 yılları arasındaki aylık yağış ve sıcaklık verileri temin edilmiştir. Kullanılan istasyonların konum bilgileri ile yağış ve sıcaklık verilerinin temel istatistiksel özellikleri Tablo 1’de verilmiştir.

Tablo 1. İstasyonların istatistiksel bilgileri

İstasyon No/ Adı	Enlem Boylam	Zaman Aralığı	Yağış (mm)			Sıcaklık (°C)		
			En düşük	Ort.	En yüksek	En düşük	Ort.	En yüksek
17191 Cihanbeyli	38°39' 02.1" 32°55' 18.7"	1985-2021	0.1	27.8	153.7	-7.0	11.81	28.4
17239 Akşehir	38°22' 46.9" 31°25' 46.9"	1985-2021	0.2	43.8	298.3	-5.0	12.17	26.7
17244 Konya havalimanı	37°59' 01.3" 32°34' 26.4"	1985-2021	0.0	27.2	124.0	-8.0	11.84	27.7
17248 Ereğli	37°31' 31.8" 34°02' 54.6"	1985-2021	0.0	25.7	97.7	-8.5	12.23	26.6
17754 Kulu	39°04' 43.7" 33°03' 56.5"	1985-2021	0.0	31.7	130.0	-7.5	10.80	26.5
17798 Yunak	38°49' 13.8" 31°43' 32.9"	1985-2021	0.0	36.8	222.9	-4.7	11.40	26.4
17832 Ilgın	38°16' 34.7" 31°53' 38.4"	1985-2021	0.0	36.6	203.9	-7.1	11.34	25.8
17902 Karapınar	37°42' 55.1" 33°31' 33.6"	1985-2021	0.0	25.2	142.6	-9.4	11.42	25.7
17928 Hadim	36°59' 21.5" 32°27' 20.5"	1985-2021	0.0	26.7	114.8	-7.4	10.22	24.8

Tablo 1 incelendiğinde, Konya ili genelinde yıllık ortalama sıcaklıkların 10–12 °C arasında değiştiği, yağış miktarlarının ise istasyonlar arasında belirgin farklılık gösterdiği görülmektedir. Özellikle Akşehir, Yunak ve Ilgın istasyonlarının nispeten yüksek yağış değerlerine sahip olduğu, buna karşılık Ereğli ve Karapınar istasyonlarında yağış miktarlarının oldukça düşük olduğu dikkat çekmektedir. Bu durum, ilin kuzeybatısından güneydoğusuna doğru artan kuraklık eğilimini yansıtmaktadır.

2.2. Keşif kuraklık indisi

Keşif Kuraklık İndisi (KKİ), tarımsal ve meteorolojik kuraklığın izlenmesi amacıyla ilk kez Tsakiris ve Vangelis [20] tarafından önerilmiştir. Özellikle kurak ve yarı kurak bölgelerde yaygın olarak kullanılmaktadır. KKİ, yağış verisi ile PET değerini de dikkate aldığı için kuraklık koşullarını daha gerçekçi ve güvenilir biçimde tahmin etmeyi amaçlamaktadır [21], [22]. KKİ, üç aşamalı bir hesaplama süreci ile elde edilmektedir. İlk adımda, indeksin başlangıç değeri olan α_k hesaplanır. Bu değer, ardışık aylık yağış ve PET verileri kullanılarak her yıl için Denklem (1)' de gösterildiği şekilde hesaplanmaktadır:

$$\alpha_k = \frac{\sum_{j=1}^{j=k} P_j}{\sum_{i=k}^{j=k} PET_j} \quad i = 1, 2, \dots, N \quad j = 1, 2, \dots, k \quad (1)$$

Burada P_{ij} ve PET_{ij} sırasıyla i . yılın j . ayına ait yağış ve PET değerlerini temsil eder. $k=1$ Ekim ayını, $k=12$ ise Eylül ayını ifade eder. N , veri setindeki toplam yıl sayısını göstermektedir.

İkinci aşamada, normalleştirilmiş KKİ (KKI_n) hesaplanır. Bu işlem, α_k değerlerinin aritmetik ortalaması olan $\bar{\alpha}_k$ kullanılarak Denklem (2) ile gerçekleştirilir:

$$KKI_n(k) = \frac{\alpha_k}{\bar{\alpha}_k} - 1 \quad (2)$$

Üçüncü aşamada ise standartlaştırılmış KKİ (KKI_{std}) elde edilir. Bu amaçla, α_k değerlerinin doğal logaritması alınarak y_k serisi oluşturulur. Ardından bu serinin aritmetik ortalaması (\bar{y}_k) ve standart sapması (σ_k) kullanılarak Denklem (3) uygulanır [23], [24]:

$$KKI_{std}(k) = \frac{y_k - \bar{y}_k}{\sigma_k} \quad (3)$$

Bu üç aşamalı KKİ hesaplama yöntemiyle, kuraklık şiddeti hem mutlak değerler hem de istatistiksel olarak normalize edilmiş biçimde analiz edilebilmektedir. Tablo 2'de, KKI_{std} değerlerine göre kuraklık sınıflamaları sunulmaktadır.

Tablo 2. KKİ kuraklık sınıfları [5]

KKİ Değerleri	Kuraklık Sınıfları
2.00 ve üzeri	Aşırı nemli
1.50 ile 1.99 arası	Çok nemli
1.00 ile 1.49 arası	Orta derecede nemli
-0.49 ile 0.99 arası	Normal koşullar
-0.99 ile -0.50 arası	Hafif kuraklık
-1.49 ile -1.00 arası	Orta şiddette kuraklık
-1.99 ile -1.50 arası	Şiddetli kuraklık
-2.00 ve daha az	Aşırı kuraklık

Bu çalışmada PET hesaplamasında, literatürde yaygın olarak kullanılan ve aylık ortalama sıcaklık ile enlem değerlerine dayanan Thornthwaite yöntemi uygulanmıştır [25], [26], [27]. İlk kez Thornthwaite [28] tarafından önerilen bu sıcaklık tabanlı yöntemde, seçilen istasyonun enlem, boylam ve aylık ortalama sıcaklık değerlerinin bilinmesi gerekmektedir [27]. Thornthwaite yöntemi, yağıştan toprağa ulaşan suyun buharlaşma yoluyla atmosfere geri dönmesini temsil eden fiziksel bir süreç olarak kabul edilmektedir [29]. Bu yöntem ile aylık PET değerleri, Denklem (4-7)'deki gibi hesaplanmaktadır.

$$PET(T) = 16 * \left(\frac{10 * T}{I}\right)^A * G \quad (4)$$

$$i = \left(\frac{T}{5}\right)^{1.514} \quad (5)$$

$$I = \sum_{1}^{12} i \quad (6)$$

$$A = 6.7510 * 10^{-7} * I^3 - 7.7110 * 10^{-5} * I^2 + 1.791210 * 10^{-2} * I + 0.49239 \quad (7)$$

Yukarıdaki denklemlerde, $PET(T)$, potansiyel evapotranspirasyon (mm), i aylık sıcaklık indisi, T aylık ortalama sıcaklık ($^{\circ}C$), I yıllık sıcaklık indisi, A bir parametre ve G enlem düzeltme katsayısı olarak tanımlanmaktadır [28], [30].

2.3. Dalgacık dönüşümü

Dalgacık dönüşümü, durağan olmayan zaman serilerinin hem zamansal hem de frekans alanındaki bileşenlerini aynı anda incelemeye olanak tanıyan güçlü bir analiz yöntemidir. Fourier dönüşümünden farklı olarak, sinyallerdeki kısa süreli değişimleri de yakalayabilme yeteneğine sahiptir. Bu sayede, serinin yüksek frekanslı (kısa dönemli) bileşenleri ile düşük frekanslı (uzun dönemli) bileşenleri eş zamanlı olarak analiz edilebilir [31], [32].

Dalgacık dönüşümünde kullanılan temel fonksiyon “ana dalgacık” (mother wavelet) olarak adlandırılır. Ana dalgacık, incelenecek sinyalin karakterine en uygun olacak şekilde seçilir ve farklı dalgacık ailelerinden (örneğin Daubechies, Symlet, Coiflet, Dmey) biri tercih edilebilir. Uygun dalgacık seçimi, analiz edilen sinyalin yapısını doğru biçimde temsil edebilmek açısından kritik öneme sahiptir. Dalgacık dönüşümünün en önemli avantajı, zaman–frekans çözünürlüğünü ölçeklere bağlı olarak optimize edebilmesidir. Yüksek frekanslarda kısa, düşük frekanslarda ise geniş zaman pencereleri kullanarak hem kısa vadeli dalgalanmalar hem de uzun vadeli eğilimler aynı anda değerlendirilebilir [33].

Dalgacık dönüşümü genel olarak iki ana kategoriye ayrılır: Sürekli Dalgacık Dönüşümü (SDD) ve Ayrık Dalgacık Dönüşümü (ADD). SDD, sinyalin tüm ölçeklerde kesintisiz olarak analiz edilmesine olanak tanıırken, ADD belirli ölçek–konum çiftlerini kullanarak daha az veriyle çalışır ve böylece hesaplama yükünü önemli ölçüde azaltır. Bu yönüyle, ADD hem orijinal sinyalin analizinde hem de yeniden sentezinde yeterli bilgi sağlayarak pratik uygulamalarda daha verimli bir çözüm sunar. Ölçekleme ve öteleme işlemlerinin ikinin üsleri biçiminde seçilmesi, sürekli dalgacık dönüşümüne kıyasla daha etkin ve yüksek doğrulukta bir çözümleme yapılmasına imkân tanır [34], [35]. Bu avantajlar nedeniyle mühendislik alanındaki dalgacık tabanlı çalışmaların büyük çoğunluğu ADD kullanılarak gerçekleştirilmektedir [36]. ADD, Denklem (8)’de verildiği şekilde uygulanır.

$$\Psi_{m,n} \left(\frac{t - \tau}{S} \right) = S_0^{-m/2} \Psi \left(\frac{t - n\tau_0 S_0}{S_0^m} \right) \quad (8)$$

Burada m ve n tamsayıdır. m , dalgacığın ölçek eksenindeki konumunu, n ise zaman eksenindeki öteleme miktarını göstermektedir. S_0 sabit ölçekleme adımını, τ_0 ise zaman eksenindeki öteleme aralığını ifade eder. İkisinin üsleri kullanılarak tanımlanan dalgacık fonksiyonu Denklem (9)’da verilmiştir.

$$\Psi_{m,n}(t) = 2^{-m/2} \Psi(2^{-m}t - n) \quad (9)$$

Ayrık bir i adım büyüklüğüne sahip $x(t)$ zaman serisi için ADD Denklem (10) ile hesaplanmaktadır.

$$W_{m,n} = 2^{-m/2} \sum_{i=0}^{N-1} X_i \Psi(2^{-m}i - n) \quad (10)$$

Burada $W_{m,n}$, $s=2^m$ ölçeği ve $t=2^m n$ zamanı temsil eden dalgacık katsayılarını ifade eder. X_i , $i=1, \dots, N-1$ aralığında tanımlanan sonlu bir zaman serisidir ve N , $N=2^M$ şeklinde ifade edilen ikinin üssü bir tamsayıdır. $1 < m < M$ aralığında 2^m ölçeğinde ayrıştırma yapılır. $m = M$ olduğu en geniş ölçekte tüm zaman serisini kapsayacak yalnızca bir dalgacık bulunur. Bir sonraki ölçekte (2^{M-1}) iki dalgacık elde edilir ve iki katsayı üretilir. Bu işlem $m = 1$ olana kadar yinelenir. Bu işlemlerden sonra boyutu $N = 2^M$ olan bir ayrık zaman serisini ifade edecek toplam katsayı sayısı $1+2+4+\dots+2^{M-1}$ olur. Bu yapı, zaman serisinin farklı zaman ve ölçeklerdeki değişimini ortaya koyar [37].

Mallat [33] tarafından geliştirilen çok çözünürlüklü analiz algoritmasında, orijinal $x(t)$ sinyali “yaklaşım” ve “detay” bileşenleri olarak ikiye ayrılmaktadır. Bu ayrımın temelinde, sinyalin düşük ve yüksek frekans bileşenlerine ayrıştırılması bulunmaktadır. İlk olarak, sinyal alçak ve yüksek geçiren filtrelerden geçirilerek yaklaşık ($y_{alçak}(k)$) ve detay ($y_{yüksek}(k)$) bileşenlerine ayrılır. Bu işlemler Denklem (11) ve (12)’de verilmiştir.

$$y_{yüksek}(k) = \sum_n x(q) \cdot g(2k - q) \quad (11)$$

$$y_{alçak}(k) = \sum_n x(q) \cdot h(2k - q) \quad (12)$$

Burada, orijinal işaret $x(q)$, $g(q)$ yüksek geçiren ve $h(q)$ alçak geçiren filtrelerinden geçirilerek bileşenlerine ayrıştırılır. $y_{yüksek}(k)$ ve $y_{alçak}(k)$ sırasıyla bu filtrelerin çıkışlarını ve q zamanı temsil etmektedir. Bu yöntem, sinyalin çoklu çözünürlük düzeylerinde analiz edilmesini sağlayarak zaman serilerinin karmaşık yapısının ayrıntılı şekilde incelenmesine olanak tanımaktadır [14], [34], [35].

Bu çalışmada ADD kullanılarak veri serileri çok çözünürlüklü ayrıştırmaya tabi tutulmuştur. Ön değerlendirme aşamasında farklı dalgacık aileleri (Dmey, Haar, Coif, Fk ve Sym) karşılaştırılmış ve ayrıştırma sonucunda elde edilen alt bileşenler ile hedef değişken arasındaki korelasyon yapıları incelenmiştir. Daha dengeli ve kararlı ilişki yapısını sağlayan Dmey dalgacığı seçilmiştir. Ayrıca, veri serisinin 444 aylık uzunluğu dikkate alınarak ayrıştırma işlemi sonucunda sekiz alt bileşen elde edilmiştir.

2.4. Makine öğrenmesi

Makine öğrenmesi (ML), yapay zekâ alanının bir alt dalı olup, belirli problemlerin çözümünde verileri eğitim, doğrulama ve test süreçlerinden geçirilerek tahminsel çıktılar üreten bir algoritmik yaklaşımdır. Bu süreçte çeşitli modeller oluşturulur, eğitilir ve en uygun performans seviyesine ulaşmak amacıyla optimize edilir [38]. ML, veri odaklı problemlerin çözümünde farklı algoritmalara dayanır. Uygulanacak algoritmanın türü; problemin yapısına, veri setindeki değişkenlerin sayısına ve veri türüne bağlı olarak belirlenir. Bu nedenle en uygun modelin seçimi, probleme özgü koşulların dikkatle değerlendirilmesini gerektirir [39]. Literatürdeki kuraklık çalışmalarında yüksek başarı oranları, güçlü genelleme yetenekleri ve aşırı öğrenmeye karşı dayanıklı yapılarıyla öne çıkan K-En Yakın Komşu, Doğrusal Regresyon, Ridge, Karar Ağacı, AdaBoost, Rastgele Ormanlar, Ekstra Ağaç, Gradyan Artırma ve Aşırı Gradyan Artırma algoritmaları bu çalışmada ele alınmış ve aşağıda özetlenmiştir [40], [41], [42], [43], [44].

Bu çalışmada geliştirilen modellerde veriler %80 eğitim ve %20 test seti olarak rastgele ayrılmıştır. Bu tercih, kullanılan algoritmaların aynı veri dağılımı altında karşılaştırmalı olarak değerlendirilmesini sağlamak amacıyla benimsenmiştir. Bununla birlikte, rastgele veri bölme yaklaşımı zaman serilerinin zamansal bağımlılık yapısını tam olarak yansıtmayabilir. Karşılaştırmalı performans değerlendirmesi için algoritmaların varsayılan hiperparametre ayarları korunmuş, model performansının daha güvenilir biçimde değerlendirilmesi amacıyla eğitim verisi üzerinde beş katlı çapraz doğrulama uygulanmıştır.

2.4.1. K-en yakın komşu (KNN) algoritması

İlk kez Fix ve Hodges [45] tarafından geliştirilen KNN algoritmasında, bir veri noktasının hedef değeri, çok boyutlu uzayda kendisine en yakın komşu noktaların hedef değerleri temel alınarak tahmin edilir [46], [47].

2.4.2. Doğrusal regresyon (DR) algoritması

Doğrusal regresyon, bir bağımlı değişken ile bir veya daha fazla bağımsız değişken arasındaki ilişkiyi açıklamak amacıyla kullanılan istatistiksel bir ML algoritmasıdır [48].

2.4.3. Ridge regresyon algoritması

Hoerl ve Kennard [49] tarafından önerilen bu algoritma, klasik en küçük kareler yönteminin çoklu doğrusal bağlantı (multicollinearity) sorununa çözüm getiren bir varyantıdır. Bu yöntemde, regresyon katsayılarının varyansını azaltmak amacıyla kayıp fonksiyonuna bir ceza terimi eklenir. Çoklu doğrusal regresyonda $X'X$ olarak kabul edilen matrisinin köşegen elemanları $k > 0$ olmak üzere k ridge parametresi eklenerek katsayılar ve parametre tahmininin varyansı küçültülür.

2.4.4. Karar ağacı (KA) algoritması

Hem sınıflandırma hem de regresyon problemlerinde kullanılan ML algoritmasıdır. Girdi özelliklerine göre veri uzayını bölümlere ayırır ve bu bölümleri düğümler şeklinde temsil eder [50]. Modelin temel bileşenleri; kök düğüm, dallar ve yaprak düğümleridir. Kök düğüm, hedef değişkeni temel alan ilk ayrımı ifade ederken, yaprak düğümler nihai tahmin veya sınıflandırma sonucunu gösterir. Bu yapı, karar süreçlerinin görsel olarak kolay anlaşılmasını sağlar [51].

2.4.5. Adaboost algoritması

Yavv Freund ve Robert Schapire [52] tarafından geliştirilen, zayıf sınıflandırıcıların hatalarını yinelemeli olarak düzelterek güçlü bir sınıflandırıcı oluşturan bir topluluk (ensemble) yöntemidir [52], [53]. Bu algoritma, üstel bir kayıp fonksiyonunu minimize ederek sınıflandırma doğruluğunu artırmayı amaçlar [54].

2.4.6. Rastgele ormanlar (RO) algoritması

Leo Breiman [55] tarafından geliştirilen bu algoritma birden fazla karar ağacını birleştirerek yüksek doğrulukta tahminler üreten bir topluluk yöntemidir [56]. Her bir ağaç, veri kümesinden rastgele seçilen bir alt örnekle oluşturulur ve nihai tahmin, tüm ağaçların ortalaması alınarak elde edilir [57].

2.4.7. Ekstra ağaç (EA) algoritması

RO algoritmasına benzer şekilde çalışır ancak her bölünmede rastgele eşik değerleri belirleyerek daha yüksek çeşitlilik sağlar. Gürültülü ve yüksek boyutlu verilerde başarılı performans sergilemesiyle bilinmektedir [58], [59].

2.4.8. Gradyan artırma (GA) algoritması

Friedman [60] tarafından geliştirilen bu algoritma, zayıf öğrenenleri aşamalı biçimde birleştirerek güçlü bir tahmin modeli oluşturur [61], [62]. Gradyan Artırma, kayıp fonksiyonunun gradyanını izleyerek model hatalarını sistematik biçimde azaltır.

2.4.9. Aşırı gradyan artırma (XGBoost) algoritması

Ağaç tabanlı modellerin verimliliğini artıran ölçeklenebilir bir Gradyan Artırma algoritmasıdır. Yüksek esneklik, güçlü genelleme yeteneği, paralel işlem desteği ve hesaplama verimliliği gibi avantajlara sahiptir [63].

3. Bulgular

Bu çalışmada, Konya iline ait meteorolojik kuraklık değerlerini tahmin etmek amacıyla dalgacık dönüşümü ve makine öğrenmesi yöntemlerinden yararlanılmıştır. İlk olarak, bölgedeki meteoroloji istasyonlarından elde edilen 1985–2021 yıllarına ait aylık toplam yağış ve ortalama sıcaklık verileri incelenmiş, eksik gözlemler tamamlanmış ve homojenlik analizleri gerçekleştirilmiştir. Homojenliği sağlanan bu veriler kullanılarak 9- ve 12- aylık zaman ölçekleri için KKİ değerleri hesaplanmıştır. Daha sonra bu değerler, dalgacık dönüşümüyle elde edilen alt serilerle birlikte makine öğrenmesi modellerinin girdisi olarak kullanılmıştır. Son aşamada ise geliştirilen modellerin eğilimleri Mann–Kendall eğilim testiyle değerlendirilmiştir.

Modellerin performansını değerlendirmek için iki temel istatistiksel ölçüt kullanılmıştır: belirleyicilik katsayısı (R^2) ve karekök ortalama hata (KOH). R^2 değeri 0 ile 1 arasında değer alır. Değerin 1'e yaklaşması, modelin yüksek bir tahmin başarısına sahip olduğunu; 0'a yaklaşması ise açıklayıcılığın zayıf olduğunu gösterir. Bu katsayı, bağımsız değişkenlerin bağımlı değişkendeki toplam varyansı yüzde olarak ne ölçüde açıkladığını ifade eder [64]. R^2 değeri Denklem (17) ile hesaplanmıştır.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \bar{y}_i)^2}{\sum_{i=1}^n (y_i - y_{ort})^2} \quad (17)$$

KOH değeri ise 0 ile sonsuz arasında değişir. Bu değer 0'a yaklaşması, model tahminlerinin gerçek değerlere yakın olduğunu gösterir. Ayrıca hata miktarını orijinal veri birimiyle ifade ederek standartlaştırılmış bir değerlendirme sunar [64]. KOH hesaplaması Denklem (18)'de verilmiştir.

$$KOH = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_i - \bar{y}_i)^2} \quad (18)$$

Denklem (17) ve (18)'de y_i gerçek değeri, \bar{y}_i tahmin edilen değeri, y_{ort} gerçek değerlerin ortalamasını ve N veri sayısını göstermektedir [64], [65].

Bu doğrultuda, merkez istasyon olarak seçilen Konya Havalimanı istasyonunun 9- ve 12- aylık KKİ değerlerini tahmin etmek amacıyla, diğer sekiz istasyona ait KKİ değerleri model girdisi olarak kullanılmış ve bu verilerle makine öğrenmesi (ML) modelleri geliştirilmiştir. Bu modellerin performans sonuçları Tablo 3'te sunulmuştur.

Tablo 3. ML modellerinin performans değerleri [19]

Periyot	Algoritma	Eğitim Kümesi		Test Kümesi	
		R ²	KOH	R ²	KOH
KKİ-9	KNN	0.85	0.39	0.69	0.55
	DR	0.71	0.54	0.56	0.65
	Ridge	0.71	0.54	0.56	0.65
	KA	1.00	0.00	0.36	0.79
	AdaBoost	0.80	0.45	0.56	0.65
	RO	0.97	0.18	0.64	0.59
	EA	1.00	0.00	0.69	0.55
	GA	0.95	0.22	0.66	0.57
	XGBoost	1.00	0.00	0.63	0.60
KKİ-12	KNN	0.88	0.35	0.73	0.49
	DR	0.69	0.57	0.61	0.59
	Ridge	0.69	0.57	0.61	0.59
	KA	1.00	0.00	0.43	0.71
	AdaBoost	0.80	0.46	0.57	0.62
	RO	0.97	0.17	0.67	0.55
	EA	1.00	0.00	0.75	0.48
	GA	0.96	0.21	0.70	0.52
	XGBoost	1.00	0.00	0.70	0.51

Tablo 3 incelendiğinde, tüm periyotlarda geliştirilen KA, EA ve XGBoost modellerinin eğitim ve test kümeleri arasındaki performans farklarının aşırı öğrenme (overfitting) sorununa işaret ettiği görülmektedir. Bu modeller, eğitim kümesinde R² değerinin 1.00 gibi oldukça yüksek değerlere ulaşmasına rağmen, test kümesinde belirgin şekilde daha düşük performans sergilemiştir. Bu sonuç, modellerin eğitim verisine yüksek düzeyde uyum sağladığını; ancak kısa dönemli dalgalanmaları da öğrenmeleri nedeniyle genelleme yeteneklerinin sınırlanmış olabileceğini göstermektedir. Bu durum, model karmaşıklığındaki artışın varyansın yükselmesiyle ilişkili olabileceğine işaret etmektedir. Ridge ve DR algoritmalarının benzer sonuçlar vermesi, bu yöntemlerin yapısal benzerlikleriyle açıklanabilir. Buna karşılık KNN ve Ridge algoritmaları, eğitim ve test kümeleri arasında daha dengeli bir performans sergilemiştir. Bu eğilim, ilgili algoritmaların aşırı öğrenmeye karşı daha dayanıklı olabileceğini düşündürmektedir. Literatürde de benzer bulgulara rastlanmıştır; [66] ve [67] çalışmalarında aşırı öğrenme durumları rapor edilmiştir. Bu bulgular, klasik ML modellerinin bazı durumlarda genelleme performansı açısından sınırlı kalabildiğini ve aşırı öğrenme problemini azaltmaya yönelik ek yöntemlerin yararlı olabileceğini göstermektedir. Bu kapsamda, gürültü filtreleme özelliğinden yararlanarak aşırı öğrenmeyi azaltmak ve klasik ML modellerinin performansını artırmak amacıyla Dmey dalgacığı temelli hibrit D-ML modelleri geliştirilmiştir. Alt bileşenler ile hedef değişken arasında yapılan korelasyon analizi sonucuna göre, Dmey dalgacığı karşılaştırılan dalgacık aileleri arasında daha uygun performans sergilemiş ve tüm analizlerde bu dalgacık kullanılmıştır. Böylece dalgacık seçiminin model performansı üzerindeki etkisi kontrol altına alınmış ve karşılaştırmalar aynı dönüşüm yapısı altında gerçekleştirilmiştir. Girdi olarak kullanılan sekiz istasyona ait 9- ve 12- aylık KKİ değerleri, Dmey dalgacığı yardımıyla alt serilere ayrılmıştır. Modelde kullanılacak girdi parametrelerini belirlemek için alt seriler ile çıktı parametreleri (9- ve 12- aylık KKİ değerleri) arasındaki ilişkiler korelasyon analiziyle incelenmiş ve sonuçlar Tablo 4'te sunulmuştur.

Tablo 4. Alt serilerin 9- aylık KKİ ile korelasyonu

Periyotlar	İstasyonlar	d1	d2	d3	d4	d5	d6	d7	d8
9- Aylık	Cihanbeyli	0.15	0.15	0.19	0.36	0.35	0.33	0.29	0.15
	Akşehir	0.13	0.15	0.18	0.27	0.38	0.38	0.24	-0.13
	Ereğli	0.12	0.11	0.16	0.25	0.31	0.19	0.22	0.14
	Kulu	0.14	0.15	0.20	0.20	0.35	0.26	0.25	-0.02
	Yunak	0.12	0.14	0.21	0.26	0.41	0.36	0.25	-0.14
	İlgın	0.14	0.17	0.17	0.33	0.41	0.43	0.27	-0.15
	Karapınar	0.12	0.12	0.17	0.34	0.33	0.26	0.23	0.10
	Hadim	0.15	0.16	0.19	0.32	0.44	0.36	0.21	-0.14
12- Aylık	Cihanbeyli	0.11	0.16	0.08	0.31	0.39	0.38	0.32	0.17
	Akşehir	0.09	0.15	0.08	0.21	0.43	0.44	0.28	-0.16
	Ereğli	0.09	0.12	0.09	0.21	0.36	0.17	0.24	0.16
	Kulu	0.10	0.15	0.08	0.20	0.38	0.28	0.29	0.00
	Yunak	0.10	0.15	0.06	0.21	0.45	0.41	0.30	-0.17
	İlgın	0.10	0.17	0.08	0.27	0.46	0.47	0.30	-0.18
	Karapınar	0.09	0.12	0.12	0.26	0.36	0.27	0.23	0.10
	Hadim	0.11	0.17	0.12	0.24	0.49	0.38	0.20	-0.17

Hesaplanan korelasyon değerleri, KKİ değerleri üzerinde etkili olan alt bileşenlerin belirlenmesinde önemli bir rol oynamaktadır. Tablo 4'te 9- ve 12- aylık zaman periyotlarında alt seriler ile çıktı parametresi arasındaki korelasyon değerleri sunulmuştur. Koyu renkle gösterilen değerler, 0.25'in üzerindeki korelasyonları ifade etmektedir.

Dalgacık dönüşümünün ardından kuraklık modelleri geliştirilirken üç farklı girdi kombinasyonu tasarlanmıştır. Ayrıca model performanslarının güvenilirliğini artırmak amacıyla beş çapraz doğrulama yöntemi uygulanmış ve sonuçlar değerlendirilmiştir. İlk aşamada, girdi değişkenleriyle çıktı değişkeni arasındaki korelasyon değeri 0.25'in üzerinde olan alt seriler model girdi değişkenleri olarak seçilmiş ve bu kombinasyonla D-ML1 modelleri geliştirilmiştir. Modellerin performans sonuçları Tablo 5'te verilmiştir.

Tablo 5. D-ML1 modellerinin performans değerleri (R>0.25)

Periyot	Algoritma	Eğitim kümesi		Test kümesi	
		R ²	KOH	R ²	KOH
KKİ-9	KNN	0.88	0.35	0.78	0.44
	DR	0.76	0.49	0.64	0.56
	Ridge	0.73	0.52	0.66	0.55
	KA	0.99	0.02	0.66	0.54
	AdaBoost	0.85	0.40	0.78	0.44
	RO	0.98	0.15	0.84	0.38
	EA	0.99	0.02	0.88	0.32
	GA	0.96	0.19	0.82	0.40
	XGBoost	0.99	0.02	0.86	0.35
KKİ-12	KNN	0.91	0.29	0.84	0.41
	DR	0.81	0.43	0.75	0.51
	Ridge	0.77	0.47	0.70	0.56
	KA	0.99	0.02	0.72	0.54
	AdaBoost	0.88	0.35	0.78	0.48
	RO	0.98	0.12	0.86	0.38
	EA	0.99	0.02	0.90	0.33
	GA	0.97	0.17	0.85	0.39
	XGBoost	0.99	0.02	0.86	0.38

Tablo 5 incelendiğinde, zaman periyodu uzadıkça modellerin daha başarılı sonuçlar verdiği görülmektedir. Bu bulgu, uzun zaman ölçeklerinde kuraklık serisinin yüksek frekanslı gürültü bileşenlerinin etkisinin azalmasıyla ilişkili olabilir. Ayrıca, dalgacık dönüşümünün uygulanmasıyla 9- ve 12- aylık periyotlarda EA, RO ve XGBoost algoritmalarının genelleme performanslarının belirgin bir biçimde iyileştiği görülmüştür. Fakat beş katlı çapraz doğrulama sonuçları da dikkate alındığında, en iyi performansın EA algoritmasıyla elde edildiği belirlenmiştir. KA algoritması zaman periyodu uzadıkça daha iyi sonuçlar üretse de EA algoritmasının gerisinde kalmaktadır.

İkinci aşamada, en yüksek korelasyon değerlerine sahip alt seriler girdi değişkenleri olarak kullanılmış ve bu verilerle D-ML2 modelleri geliştirilmiştir. Bu modellerin tüm zaman periyotlarındaki performans sonuçları Tablo 6'da sunulmuştur.

Tablo 6. En büyük korelasyona sahip D-ML2 modelleri performans değerleri

Periyot	Algoritma	Eğitim kümesi		Test kümesi	
		R ²	KOH	R ²	KOH
KKİ-9	KNN	0.85	0.39	0.73	0.49
	DR	0.55	0.68	0.40	0.73
	Ridge	0.54	0.68	0.41	0.72
	KA	0.99	0.02	0.60	0.59
	AdaBoost	0.77	0.49	0.59	0.60
	RO	0.97	0.17	0.78	0.44
	EA	0.99	0.02	0.86	0.35
	GA	0.94	0.25	0.73	0.49
	XGBoost	0.99	0.02	0.82	0.40
KKİ-12	KNN	0.90	0.32	0.79	0.47
	DR	0.49	0.70	0.49	0.73
	Ridge	0.49	0.70	0.48	0.73
	KA	0.99	0.02	0.76	0.50
	AdaBoost	0.79	0.46	0.67	0.59
	RO	0.98	0.15	0.80	0.45
	EA	0.99	0.02	0.86	0.38
	GA	0.94	0.24	0.78	0.48
	XGBoost	0.99	0.02	0.85	0.40

Tablo 6 incelendiğinde, 9- ve 12- aylık periyotlarda EA algoritmasının diğer algoritmalara kıyasla daha başarılı sonuçlar verdiği görülmektedir. EA algoritmasını sırasıyla XGBoost ve KA algoritmaları takip etmektedir. RO algoritması da yüksek R² değerleriyle dikkat çekmektedir; ancak eğitim ve test kümelerindeki R² değerlerinin diğer algoritmalara kıyasla daha az uyumlu olduğu gözlenmiştir. Bu nedenle, RO algoritması yüksek performans göstermesine rağmen genel başarı açısından EA algoritmasının gerisinde kalmıştır. Ancak D-ML2 modelleri D-ML1 modelleriyle kıyaslandığında bir düşüş dikkat çekmektedir. Dolayısıyla yalnızca en yüksek korelasyona sahip alt serilerin seçilmesi, model karmaşıklığını azaltsa da genelleme yeteneğini sınırlayabilmektedir.

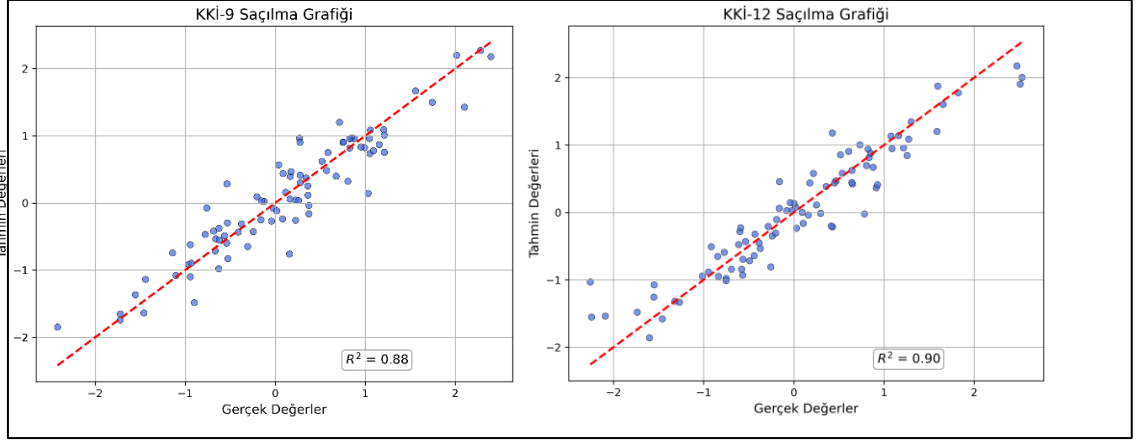
Üçüncü aşamada ise, korelasyon değeri 0.25'in üzerinde olan alt serilerin toplamı alınarak model girdi değişkenleri oluşturulmuş ve 9- ile 12- aylık KKİ değerleri tahmin edilmiştir. Bu modellerin performans sonuçları Tablo 7'de sunulmuştur.

Tablo 7. Toplanan alt seriler ile geliştirilen D-ML3 modelleri performans değerleri


Periyot	Algoritma	Eğitim kümesi		Test kümesi	
		R ²	KOH	R ²	KOH
KKİ-9	KNN	0.86	0.37	0.71	0.51
	DR	0.62	0.63	0.59	0.60
	Ridge	0.62	0.63	0.59	0.60
	KA	0.99	0.02	0.53	0.65
	AdaBoost	0.74	0.51	0.62	0.58
	RO	0.96	0.19	0.72	0.50
	EA	0.99	0.02	0.81	0.40
	GA	0.93	0.27	0.73	0.49
	XGBoost	0.99	0.02	0.71	0.51
KKİ-12	KNN	0.92	0.28	0.85	0.39
	DR	0.67	0.57	0.59	0.66
	Ridge	0.67	0.57	0.59	0.66
	KA	0.99	0.02	0.70	0.56
	AdaBoost	0.81	0.43	0.75	0.51
	RO	0.98	0.14	0.86	0.39
	EA	0.99	0.02	0.90	0.33
	GA	0.96	0.20	0.83	0.42
	XGBoost	0.99	0.02	0.83	0.42

Tablo 7 incelendiğinde, DR ve Ridge Regresyon algoritmalarının düşük R² ve yüksek KOH değerlerine sahip olduğu görülmektedir. Bu sonuç, KKİ değerlerinin doğrusal olmayan yapısıyla ilişkili olabilir. Tüm zaman periyotlarında KNN ve RO algoritmalarının eğitim ve test sonuçları arasında daha dengeli bir performans sergilediği belirlenmiştir. Bu bulgular, özellikle uzun vadeli kuraklık tahminlerinde daha dengeli sonuçlar elde edilebileceğini göstermektedir. Fakat alt serilerin toplanması, ayrıştırılmış bir yapıyı tekrar birleştirdiği için D-ML1 modeliyle kıyaslandığında daha düşük sonuçlar verdiği görülmüştür. En iyi sonuç ise yine EA algoritmasıyla elde edilmiştir ancak D-ML1 modelinde elde edilen seviyelere çıkamamıştır.

Klasik ML modelleri ile tüm D-ML modelleri karşılaştırıldığında, D-ML modellerinin genel olarak daha iyi sonuçlar verdiği görülmektedir. Üç farklı girdi kombinasyonu kullanılarak oluşturulan D-ML modelleri arasında, her iki zaman periyodunda da en iyi sonuçların D-ML1 modellerinde (alt seriler ile çıktı arasındaki korelasyon değeri 0.25'in üzerinde olanların kullanıldığı model) EA algoritmasıyla elde edildiği belirlenmiştir. D-ML3 modelleri bazı durumlarda yüksek performans değerleri göstermesine rağmen sonuçlar algoritmalar arasında değişkenlik göstermektedir. En iyi sonuç veren EA algoritmasının tahmin performansını daha iyi görebilmek için test kümesine ait saçılma ve zaman serisi grafikleri incelenmiştir. Şekil 2'de, model sonuçları ile KKİ değerleri arasındaki uyum 45°'lik doğruya göre gösterilmiştir. Şekil 3 ise, tahmin edilen ve gözlenen KKİ değerlerinin zaman içerisindeki değişimini karşılaştırmalı olarak sunmaktadır.



Şekil 2. 9- ve 12- aylık zaman periyotları için test setine ait EA modeli saçılma grafiği



Şekil 3. 9- ve 12- aylık zaman periyotları için test setine ait EA modeli zaman serileri

Şekil 2 ve Şekil 3 incelendiğinde, 9- ve 12- aylık periyotta D-ML1 modellerinde EA yöntemi kullanılarak elde edilen R^2 değerlerinin bir göstergesi olarak, tahmin sonuçlarının gözlemlenen kuraklık verileriyle oldukça uyumlu olduğu görülmektedir. Grafik denklemlerinin tamamının $y=x$ çizgisine yaklaşması, modellerin sistematik ve tutarlı tahminler ürettiğini göstermektedir. Bu durum hem eğitim hem de test kümelerinde modellerin genelleme yeteneklerinin güçlü olduğuna işaret etmektedir. Tahmin edilen ve gözlenen değerlerin dağılımlarındaki benzerlik ise, modellerin kuraklık değişimlerini yüksek doğrulukla yakalayabildiğini ortaya koymaktadır.

Son aşamada, geliştirilen ML ve D-ML modellerinin hem eğitim hem de test kümelerindeki eğilimleri, hesaplanan KKI değerleriyle karşılaştırmak amacıyla Mann-Kendall eğilim testi uygulanmıştır. Analizler 9- ve 12- aylık zaman periyotları için gerçekleştirilmiş olup anlamlılık düzeyi (α) 0.05 olarak seçilmiş, buna karşılık gelen $Z_{\alpha/2}$ değeri 1.96 olarak belirlenmiştir. Tablo 8-11'de verilen Z değerlerinin negatif (-) olması azalan eğilimi, pozitif (+) olması ise artan eğilimi ifade etmektedir. Kendall'ın Tau katsayısı -1 ile +1 arasında değer almakta olup eğilimin yönü ve büyüklüğünü temsil etmektedir [68].

Tablo 8 ve 9'da Konya Havalimanı istasyonunun KKI değerlerini tahmin etmek için diğer sekiz istasyondan elde edilen verilerle geliştirilen klasik ML-EA modelinin eğitim ve test kümeleri için eğilim analizi sonuçları sunulmuştur. Tablo 10 ve 11'de ise D-ML1-EA modeline ait eğitim ve test kümeleri için eğilim analizi sonuçları verilmiştir.

Tablo 8. ML-EA modelinin eğitim kümesi için eğilim analizi

Periyot		p	Z	Tau	Eğilim	H ₀ hipotezi
KKİ-9	Gerçek	0.97	0.03	0.00	Eğilim yok	Kabul
	Tahmin	0.97	-0.04	0.00	Eğilim yok	Kabul
KKİ-12	Gerçek	0.56	0.58	0.00	Eğilim yok	Kabul
	Tahmin	0.57	0.57	0.00	Eğilim yok	Kabul

Tablo 9. ML-EA modelinin test kümesi için eğilim analizi

Periyot		p	Z	Tau	Eğilim	H ₀ hipotezi
KKİ-9	Gerçek	0.97	0.03	0.00	Eğilim yok	Kabul
	Tahmin	0.72	-0.35	-0.03	Eğilim yok	Kabul
KKİ-12	Gerçek	0.75	0.31	0.00	Eğilim yok	Kabul
	Tahmin	0.55	0.60	0.00	Eğilim yok	Kabul

Tablo 10. D-ML1-EA modelinin eğitim kümesi için eğilim analizi

Periyot		p	Z	Tau	Eğilim	H ₀ hipotezi
KKİ-9	Gerçek	0.26	-1.11	-0.04	Eğilim yok	Kabul
	Tahmin	0.27	-1.10	-0.04	Eğilim yok	Kabul
KKİ-12	Gerçek	0.28	-1.06	-0.03	Eğilim yok	Kabul
	Tahmin	0.28	-1.06	-0.03	Eğilim yok	Kabul

Tablo 11. D-ML1-EA modelinin test kümesi için eğilim analizi

Periyot		p	Z	Tau	Eğilim	H ₀ hipotezi
KKİ-9	Gerçek	0.57	-0.56	-0.04	Eğilim yok	Kabul
	Tahmin	0.94	0.07	0.00	Eğilim yok	Kabul
KKİ-12	Gerçek	1.00	0.00	-0.0002	Eğilim yok	Kabul
	Tahmin	0.91	-0.10	-0.008	Eğilim yok	Kabul

Tablo 8–11 incelendiğinde, tüm periyotlarda mutlak Z değerlerinin α anlamlılık düzeyine karşılık gelen kritik Z değerinden küçük olduğu görülmektedir. Bu nedenle H_0 hipotezi kabul edilmiştir. Ayrıca tüm periyotlarda p değerlerinin 0.05'ten büyük olduğu belirlenmiştir.

ML modelleri ile D-ML1 modellerinin eğilimleri karşılaştırıldığında, D-ML1 modellerinin eğitim kümelerindeki p değerlerinin, gerçek ve tahmin değerleri açısından ML modellerine göre birbirine daha yakın olduğu görülmüştür. Bu durum, D-ML1 modellerinin daha iyi bir öğrenme performansı sergilediğini göstermektedir. Bununla birlikte, tüm modellerde istatistiksel olarak anlamlı bir eğilim bulunmamış, dolayısıyla zamanla sistematik bir sapma gözlenmemiştir.

4. Tartışma ve Sonuç

Bu çalışmada, yarı kurak iklim özelliklerine sahip İç Anadolu Bölgesi'nde yer alan Konya ilindeki dokuz meteoroloji gözlem istasyonuna (Cihanbeyli, Akşehir, Konya Havalimanı, Ereğli, Kulu, Yunak, Ilgın, Karapınar ve Hadim) ait 1985–2021 yılları arasındaki veriler kullanılarak kuraklık analizi gerçekleştirilmiştir. Kuraklık analizinde 9- ve 12- aylık periyotlar için Keşif Kuraklık İndisi (KKİ) kullanılmıştır.

Konya ili için geliştirilen ML modellerinin performansları değerlendirilmiş; Konya Havalimanı istasyonuna ait KKİ değerleri çıktı değişkeni, diğer sekiz istasyona ait KKİ değerleri ise model girdileri olarak kullanılmıştır. Karar Ağacı, Ekstra Ağaç ve Aşırı Gradyan Artırma algoritmaları eğitim kümesinde yüksek performans sergilemiştir. Ancak test kümelerinde hata değerlerinin belirgin şekilde artması, bu modellerde aşırı öğrenme eğiliminin ortaya çıktığını göstermektedir. Model performansını iyileştirmek amacıyla veri ön işleme tekniklerinden biri olan dalgacık dönüşümü uygulanmış ve KKİ değerleri alt serilere ayrılarak D-ML modelleri oluşturulmuştur. Bu modellerde özellikle Ekstra Ağaç algoritması uzun vadeli periyotlarda daha yüksek tahmin başarısı sunduğu görülmüştür.

Genel olarak, D-ML modelleri ML modellerine kıyasla daha yüksek performans değerleri ürettiği belirlenmiştir. Korelasyon değeri 0.25'in üzerinde olan alt serilerin veya bu serilerin toplamalarının girdi olarak kullanıldığı modellerde daha yüksek R^2 değerlerine ulaşılmıştır. Mann–Kendall eğilim analizi sonuçlarına göre hem ML hem de D-ML modellerinde tüm periyotlar için eğitim ve test kümelerinde istatistiksel olarak anlamlı bir eğilim gözlenmemiş ve H_0 hipotezi kabul edilmiştir.

Sonuç olarak, bu çalışma kapsamında dalgacık dönüşümü tekniğinin makine öğrenmesi modelleriyle birlikte kullanımının, model performansını iyileştirme ve aşırı öğrenme eğilimini azaltma açısından katkı sunduğu değerlendirilmiştir. Özellikle 9- ve 12- aylık periyotlarda elde edilen yüksek R^2 değerleri, hibrit yaklaşımın uzun vadeli kuraklık tahminlerinde umut verici bir yöntemsel çerçeveye sunduğunu göstermektedir.

Bununla birlikte, veri setinin rastgele eğitim ve test alt kümelerine ayrılması, zaman serilerinin zamansal bağımlılık yapısını tam olarak yansıtamaması nedeniyle çalışmanın önemli sınırlılıklarından biri olarak değerlendirilebilir. Ayrıca, modeller arasındaki performans farkları bu çalışmada betimsel performans ölçütleri üzerinden incelenmiştir. Gelecek çalışmalarda, kronolojik veri bölme stratejilerinin ve zaman serilerine uygun doğrulama yaklaşımlarının kullanılması ile performans farklarının istatistiksel anlamlılığının uygun testlerle değerlendirilmesi, sonuçların metodolojik sağlamlığını ve güvenilirliğini daha da artırabilir.



Hakem: Dış, Bağımsız.

Teşekkür:

-

Beyanname:

1. Özgünlük Beyanı:

Bu çalışma özgündür.

2. Yazar Katkıları:

Fikir: GY,ÖT; **Kavramsallaştırma:** GY,ÖT; **Literatür Taraması:** GY,ÖT; **Veri Toplama:** GY,ÖT; **Veri İşleme:** GY,ÖT; **Analiz:** GY,ÖT; **Yazma – orijinal taslak:** GY,ÖT; **Yazma – inceleme ve düzenleme:** GY,ÖT.

3. Etik Kurul İzni:

Etik Kurul İzni gerekmemektedir.

4. Finansman/Destek:

Bu çalışma, herhangi bir finansman ya da destek almamıştır.

5. Çıkar Çatışması:

Yazarlar, herhangi bir çıkar çatışması olmadığını beyan etmektedirler.

6. Üretken Yapay Zeka Beyanı:

Çalışmanın hiçbir safhasında yapay zeka araçlarından faydalanılmamıştır.

7. Sürdürülebilir Kalkınma Amaçları:



KAYNAKÇA

- [1] Carroll, C. J., Slette, I. J., Griffin-Nolan, R. J., Baur, L. E., Hoffman, A. M., Denton, E. M., Gray, J. E., Post, A. K., Johnston, M. K., Yu, Q., Collins, S. L., Luo, Y. L., Smith, M. D., Knapp, A. K. 2021. Is a drought in grasslands? Productivity responses to different types of drought. *Oecologia*, 197, 1017-1026.
- [2] Minea, I., Iosub, M., Boicu, D. 2022. Multi-Scale approach for different type of drought in temperate climatic conditions. *Natural Hazards*, 110, 1153-1177.
- [3] Mukherjee, S., Mishra, A., Trenberth, K. E. 2018. Climate Change and drought: a perspective on drought indices. *Current Climate Change Reports*, 4, 145-163.
- [4] Naumann, G., Alfieri, L., Wyser, K., Mentaschi, L., Betts, R. A., Carrao, H., Spinoni, J., Vogt, J., Feyen, L. 2018. Global changes in drought conditions under different levels of warming. *Geophysical Research Letters*, 45(7), 3285-3296. <https://doi.org/10.1002/2017GL076521>
- [5] Tigkas, D., Vangelis, H., Tsakiris, G. 2012. Drought and climatic change impact on streamflow in small watersheds. *Science of the Total Environment*, 440, 33-41. <https://doi.org/10.1016/j.scitotenv.2012.08.035>
- [6] Mishra, A. K., Singh, V. P. 2011. Drought modeling – A review. *Journal of Hydrology*, 403(1-2), 157-175. <https://doi.org/10.1016/j.jhydrol.2011.03.049>
- [7] Wilhite, D. A., Glantz, M. H. 1985. Understanding: the drought phenomenon: the role of definitions. *Water International*, 10(3), 111-120. <https://doi.org/10.1080/02508068508686328>
- [8] Sarış, F., Gedik, F. 2021. Konya Kapalı Havzası'nda meteorolojik kuraklık analizi. *Coğrafya Dergisi*, (42), 295-308.
- [9] Özlen, T. 2022. Servikal kanserlerin teşhisinde kullanılan makine öğrenmesi algoritmalarının karşılaştırmalı analizi. *İstanbul Aydın Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans*

- Tezi, 100s, İstanbul.
- [10] Ziya, U., Hınıs, M. A. 2024. Günlük akarsu akım verilerinin destek vektör makinesi ve dalgacık dönüşümü ile modellenmesi: Çoruh Havzası Büyükdere Çayı örneği. Karamanoğlu Mehmetbey Üniversitesi Mühendislik ve Doğa Bilimleri Dergisi, 6(2), 18-32. <https://doi.org/10.55213/kmujens.1477330>
- [11] Asadi Zarch, M. A., Malekinezhad, H., Mobin, M. H., Dastorani, M. T., Kousari, M. R. 2011. Drought monitoring by reconnaissance drought index (RDI) In Iran. Water Resources Management, 25, 3485-3504.
- [12] Zarei, A. R., Moghimi, M. M., Mahmoudi, M. R. 2016. Analysis of Changes in spatial pattern of drought using RDI index in South of Iran. Water Resources Management, 30, 3723-3743.
- [13] Merabti, A., Meddi, M., Martins, D. S., Pereira, L. S. 2017. Comparing SPI and RDI applied at local scale as influenced by climate. Water Resources Management, 32, 1071-1085.
- [14] Terzi, Ö., Barak, M. 2015. Dalgacık-sinir ağı yaklaşımı ile yağış-akış tahmini: Kızılırmak Nehri örneği. Tarım Bilimleri Dergisi, 21(4), 546-557. https://doi.org/10.1501/Tarimbil_0000001356
- [15] Achite, M., Katipoglu, O. M., Şenocak, S., Elshaboury, N., Bazrafshan, O., Dalkılıç, H. Y. 2023. Modeling of meteorological, agricultural and hydrological droughts in semi-arid environments with various machine learning and discrete wavelet transform. Theoretical and Applied Climatology, 154(1), 413-451.
- [16] Mokhtar, A., Jalali, M., He, H., Al-Ansari, N., Elbeltagi, A., Alsafadi, K. 2021. Estimation of SPEI meteorological drought using machine learning algorithms. IEEe Access, 9, 65503-65523.
- [17] Tuğrul, T., Hınıs, M. A., Oruç, S. 2025. Comparison of LSTM and SVM methods through wavelet decomposition in drought forecasting. Earth Science Informatics, 18(1), 1-21.
- [18] T.C. Kültür ve Turizm Bakanlığı. 2025. Coğrafi Konum. <https://konya.ktb.gov.tr/TR-370533/coGRAFI-konum.html> (Erişim tarihi: 13.03.2025).
- [19] Yıldırım, G. 2024. Makine öğrenmesi algoritmaları ile Konya ili meteorolojik kuraklık tahmini. Isparta Uygulamalı Bilimler Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, 117s, Isparta.
- [20] Tsakiris, G., Vangelis, H. 2005. Establishing a drought index incorporating evapotranspiration. European Water. 9(10), 3-11.
- [21] Hassan, S. S., Goheer, M. A., Farah, H., Hafees, F., Sheraz, K., Fahad, J., Tariq, A. 2025. Geospatial assessment of climate variability and drought patterns: a case study from Pakistan. Theoretical and Applied Climatology, 156(3), 1-15.
- [22] Topçu, E., Karaçor, F., Çırağ, B., Taşkolı, İ., Acar, R. 2025. Drought assessment in the Northeastern Aras Basin using multi-parameter aggregate drought index and innovative polygon trend analysis. Earth Science Informations, 18(3), 273.
- [23] Tsakiris, G., Pangalou, D., Vangelis, H. 2007. Regional drought assessment based on the reconnaissance drought index (RDI). Water Resources Management, 21, 821-833. <https://doi.org/10.1007/s11269-006-9105-4>
- [24] Yılmaz M. U. 2023. Keşif kuraklık indeksi ve standartlaştırılmış yağış indeksi kullanılarak Kırklareli ilinde kuraklığın eğilimi ve zamansal değişkenliği. Doğal Afetler ve Çevre Dergisi, 9(2), 341-364. <https://doi.org/10.21324/dacd.1296428>
- [25] Almorox, J., Quej, V. H., Marti, P. 2015. Global Performance ranking of temperature-based approaches for evapotranspiration estimation considering Köppen climate classes. Journal of

- Hydrology, 528, 514-522. <https://doi.org/10.1016/j.hydrol.2015.06.057>
- [26] Wang, G., Gong, T., Lu, J., Lou, D., Hagan, D. F. T., Chen, T. 2018. On the long-term changes of drought over China (1948–2012) from different methods of potential evapotranspiration estimations. *International Journal of Climatology*, 38(7), 2954-2966. <https://doi.org/10.1002/joc.5475>
- [27] Trajkovic, S., Gocic, M., Pongracz, R., Bartholy, J. 2019. Adjustment of Thornthwaite Equation for estimating evapotranspiration in Vojvodina. *Theoretical and Applied Climatology*, 138, 1231-1240.
- [28] Thornthwaite, C. W. 1948. An approach toward a rational classification of climate. *Geographical Review*, 38(1), 55-94. <https://doi.org/10.2307/210739>.
- [29] Baş, E., Palta, Ş., İpek, İ. C. 2024. Türkiye'nin Batı Karadeniz Bölgesi'nde yer alan bartın ilinin Thornthwaite ve Köppen yöntemlerine göre iklim sınıflandırması. *Bartın Orman Fakültesi Dergisi*, 26(4), 329-344. <https://doi.org/10.24011/barofd.1484677>
- [30] Erdoğan Yüksel, E., Karan, Ö. F. 2024. Thortnhwaite yöntemine göre iklim tiplerinin belirlenmesi: Bursa ili örneği. *Artvin Çoruh Üniversitesi Orman Fakültesi Dergisi*, 25(1), 151-168. <https://doi.org/10.17474/artvinofd.1435376>
- [31] Torrence, C., Compo, G. P. 1998. A practical guide to wavelet analysis. *Bulletin of the American Meteorological Society*, 79(1), 61-78.
- [32] Labat, D. 2005. Recent advances in wavelet analyses: Part 1. A review of concepts. *Journal of Hydrology*, 314(1-4), 275-288.
- [33] Mallat, S. G. 1989. A theory for multiresolution signal decomposition: the wavelet representation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 11(7), 674-693.
- [34] Küçük, M., Ağırlioğlu, N. 2006. Dalgacık dönüşüm tekniği kullanılarak hidrolojik akım serilerinin modellenmesi. *İtüdergisi/d*, 5(2), 69-80.
- [35] Yılmaz, Z., Bozkurt, M. R. 2013. Ayrık dalgacık dönüşümü kullanarak aritmilere ait özniteliklerin çıkarılması. *XV. Akademik Bilişim Konferansı Bildirileri*. 23-25 Ocak, Antalya, 85-88.
- [36] Duran, K. 2013. Rüzgâr karakteristiklerinin dalgacık dönüşümü ile ortaya konması. *İstanbul Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi*, 170s, İstanbul.
- [37] Partal T. 2007. Türkiye yağış miktarlarının yapay sinir ağları ve dalgacık dönüşümü yöntemleri ile tahmini. *İstanbul Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi*, 198s, İstanbul.
- [38] Korkmaz, M., Doğan, A., Kirmaci, V. 2022. Performance Analysis of counterflow ranque-hilsch vortex tube with linear regression, support vector machines and gaussian process regression method. *Gazi Journal of Engineering Sciences*, 8(2), 361-370. <https://doi.org/10.30855/gmbd.0705015>
- [39] Akçay, İ. 2023. Hemşirelerin işten ayrılma niyetlerini etkileyen faktörlerin makine öğrenmesi yaklaşımları ile değerlendirilmesi. *Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi*, 59s, İstanbul.
- [40] Britton, A., Graham, G., Woloszyn, M. 2024. Exploring relationships between drought indices and ecological drought impacts using machine learning and explainable AI. *Journal of Applied and Service Climatology*, 18. <https://doi.org/10.46275/JOASC.2024.09.001>
- [41] En-Nagre, K., Aqnouy, M., Quarka, A., NaqviS. A. A., Bouizrou, I., El Messari, J. E. S., Tariq, A., Soufan, W., Li, W., El-Askary, H. 2024. Assessment and Prediction of meteorological drought using machine learning algorithms and climate data. *Climate Risk Management*, 45, 100630.

- <https://doi.org/10.1016/j.crm.2024.100630>
- [42] Gan, Z., Xie, X., Su, C., Ge, W., Pan, H., Yang, L. 2025. Understanding the evolutionary processes and causes of groundwater drought using an interpretable machine learning model. *Scientific Reports*, 15(1), 20981.
- [43] Ilyas, M., Niaz, R., Hussain, I., Alshahrani, M. A., Al Basheir, N. A., Almazah, M. M. 2025. Exploring seasonal drought patterns with climate data and machine learning models. *Stochastic Environmental Research and Risk Assessment*, 1-21.
- [44] Oyarzabal, R. S., Santos, L. B., Cunningham, C., Broedel, E., de Lima, G. R., Cunha-Zeri, G., Peixoto, J. S., Anochi, J. A., Garcia, K., Costa, L. C. O., Pampuch, L. A., Cuartas, L. A., Zeri, M., Guedes, M. R. G., Negri, R. G., Munoz, V. A., Cunha, A. P. 2025. Forecasting drought using machine learning: a systematic literature review. *Natural Hazards*, 1-29.
- [45] Fix, E., Hodges, J. L. 1951. Discriminatory analysis, nonparametric discriminators: consistency properties. *USAF School of Aviation Medicine*.
- [46] Lu, L., Zhu, Z. 2014. Prediction model for eating property of India rice. *Journal of Food Quality*, 37(4), 274-280. <https://doi.org/10.1111/jfq.12095>
- [47] Turan, A. K., Polat, H. 2024. Yarı denetimli makine öğrenmesi yöntemini kullanarak müzik türlerinin tespiti. *Gazi Üniversitesi Fen Bilimleri Dergisi*, 12(1), 92-107. <https://doi.org/10.29108/gujsc.1352477>
- [48] Yılmaz, M., Kanıt, R., Erdal, M., Yıldız, S., Bakış, A. 2016. Bina Bakım onarımı ödeneklerinin etkin kullanımı maksadıyla ihale bedelini etkileyen faktörlerin yapay sinir ağları ve lineer regresyon yöntemleri ile belirlenmesi. *Politeknik Dergisi*, 19(4), 461-470. <https://doi.org/10.2339/2016.19.4>
- [49] Hoerl, A. E., Kennard, R. W. 1970. Ridge regression: based estimation for nonorthogonal problems. *Technometrics*, 12(1), 55-67.
- [50] Jahanbani, M., Vahidnia, M. H., Ahamohammadi, H., Azizi, Z. 2024. Flood Susceptibility mapping through geoinformatics and ensemble learning methods, with an emphasis on the Adaboost-Decision Tree algorithm, in Mazandaran, Iran. *Earth Science Informatics*, 17(2), 1433-1457.
- [51] Baybaş, S., Akgün, Ö., Adıgüzel, E. D. C., Gürvardar, E. E., Gökpınar, E. 2024. Orman yangınlarının tahmini için makine öğrenimi yaklaşımı: Türkiye uygulaması, *Veri Bilimi Dergisi*, 7(2), 1-10.
- [52] Freund, Y., Schapire, R. E. 1997. A decision-theoretic generalization of on-line learning and an application to boosting. *Journal of Computer and System Sciences*, 55(1), 119-139. <https://doi.org/10.1006/jcss.1997.1504>
- [53] Hu, W., Hu, W., Maybank, S. 2008. Adaboost-based algorithm for network intrusion detection. *IEEE Transactions on Systems, Man and Cybernetics, Part B (Cybernetics)*, 38(2), 577-583.
- [54] Cao, J., Kwong, S., Wang, R. 2012. A noise-detection based Adaboost algorithm for mislabeled data. *Pattern Recognition*, 45(12), 4451-4465. <https://doi.org/10.1016/j.patcog.2012.05.002>
- [55] Breiman, L. 2001. Random forests. *Machine Learning*, 45, 5-32.
- [56] Parlak, M. S., Kayri, M. 2022. Öğretmenlerin E-öğrenme hazırbulunuşluk düzeylerini etkileyen faktörlerin rastgele orman algoritması yöntemi ile incelenmesi. *Van Yüzüncü Yıl Üniversitesi Eğitim Fakültesi Dergisi*, 19(3), 670-696. <https://doi.org/10.33711/yyuefd.1117068>
- [57] Abdoh, S. F., Rizka, M. A., Maghraby, F. A. 2018. Cervical Cancer diagnosis using random forest classifier with SMOTE and feature reduction techniques. *IEEE Access*, 6, 59475-59485. <https://doi.org/10.1109/ACCESS.2018.2874063>

- [58] Türkmen, E. 2021. Makine öğrenmesi yöntemleri ile banka pazarlama tahmini. İstanbul Kültür Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, 55s, İstanbul.
- [59] Özdemir, A. T. 2023. Makine öğrenmesi algoritmaları ile aritmlerin sınıflandırılması. Erciyes Üniversitesi Fen Bilimleri Enstitüsü Dergisi, 39(3), 394-402.
- [60] Friedman, J. H. 2001. Greedy function approximation: a gradient boosting machine. *Annals of Statistics*, 1189-1232.
- [61] Bayrakçı, H. C., Çiçekdemir, R. S., Özkahraman, M. 2021. Tarım arazilerinde harcanan su miktarını yapay zekâ teknikleri kullanarak belirlenmesi. *Düzce Üniversitesi Bilim ve Teknoloji Dergisi*, 9(6), 237-250. <https://doi.org/10.29130/dubited.1015690>
- [62] Yoon, J. 2021. Forecasting of real GDP growth using machine learning models: gradient boosting and random forest approach. *Computational Economics*, 57(1), 247-265.
- [63] Zhang, J., Ma, X., Zhang J., Sun, D., Zhou, X., Mi, C., Wen, H. 2023. Insights into geospatial heterogeneity of landslide susceptibility based on the SHAP-Xgboost model. *Journal of Environmental Management*, 332, 117357. <https://doi.org/10.1016/j.jenvman.2023.117357>.
- [64] Koçak, Y. 2023. Konya ili hava kalitesinin derin öğrenme teknikleriyle değerlendirilmesi. Selçuk Üniversitesi, Fen Bilimleri Enstitüsü, Yüksek Lisans Tezi, 88s, Konya.
- [65] Çıtakoğlu, H., Coşkun, Ö. 2021. Dalgacık dönüşüm modellenli yapay zekâ teknikleri kullanılarak Orta Anadolu bölge istasyonlarının yağış tahmini. *Harran Üniversitesi Mühendislik Dergisi*, 6(1), 39-54 <https://doi.org/10.46578/humder.785549>
- [66] Demirhan, T. 2015. Makine öğrenmesi algoritmalarının karmaşıklık ve doygunluk analizinin bir veri kümesi üzerinde gerçekleştirilmesi. *Trakya Üniversitesi, Fen Bilimleri Enstitüsü, Doktora Tezi*, 153s, Edirne.
- [67] Kumar, V., Kedam, N., Sharma, K. V., Mehta, D. J., Caloiero, T. 2023. Advanced machine learning techniques to improve hydrological prediction: a comparative analysis of streamflow prediction models. *Water*, 15(14), 2572.
- [68] Uğur Uzun, Y. 2023. Korelasyon analizi üzerine değerlendirmeler. Çanakkale Onsekiz Mart Üniversitesi, Lisansüstü Eğitim Enstitüsü, Yüksek Lisans Tezi, 69s, Çanakkale.

