



Makine öğrenmesi ile ileriye yönelik kuraklıkların tahmin edilmesi

Forecasting future droughts with machine learning

Türker Tuğrul^{1,*} 

¹ Gazi Üniversitesi, Teknoloji Fakültesi, İnşaat Mühendisliği Bölümü, 06500, Ankara Türkiye

Öz

İnsanlar ve yaşam alanları için tehdit oluşturan ciddi bir doğal afet olan kuraklık, ilk başta fark edilmesi zor olup, asıl etkileri gerçekleştiğinde fark edilebilmektedir. Kuraklığı tespit etmek, önlemek, izlemek ve etkilerini azaltmak için çok sayıda yöntem önerilmiştir. Bunların arasından araştırmacıların sıklıkla tercih ettiği yöntemlerden birisi Standartlaştırılmış Yağış Evapotranspirasyon İndeksi (SPEI)'dir. Bu yöntem kuraklıkların tespiti ve izlenmesi amacıyla kullanıldığı için, ileriye yönelik herhangi bir bilgi sunmamaktadır. Dolayısıyla, ileriye yönelik tahminlerin yapılabilmesi amacıyla makine öğrenmesi gibi tekniklerden yararlanılmaktadır. Bu çalışmada da Türkiye'nin batı bölgesinde yer alan Edirne için ileriye yönelik kuraklık tahmin modelleri oluşturulmuş ve bu modeller makine öğrenme yöntemleri ile analiz edilmiştir. Uzun-Kısa Süreli Bellek (LSTM) ve Destek Vektör Makinesi (SVM) tercih edilen yöntemler olmuştur. 4 farklı kuraklık modeli oluşturmak için cross-correlation yönteminden yararlanılmıştır. Hidrolik kuraklıkları en iyi temsil ettiği varsayılan 1901-2023 yılları arasındaki SPEI12 verisinden yararlanılmıştır. Ayrıca, model performanslarının artırılması amacıyla Dalgacık Dönüşümü (WT) kullanılmıştır. Model sonuçlarının irdelenebilmesi için Korelasyon Katsayısı (r), Kök Ortalama Kare Hatası (RMSE), Nash-Sutcliffe Verimliliği (NSE), Kling-Gupta Verimliliği (KGE) ve Performans İndeksi (PI), performans metriklerinden yararlanılmıştır. Elde edilen sonuçlarda, WT'den SVM'nin M02 (SVMWM02) modelinin en iyi sonucu verdiği tespit edilmiştir. Bu model, Edirne için yapılacak olan ileriye yönelik kuraklık modellerinde kullanılmalıdır.

Anahtar kelimeler: Kuraklık, Makine öğrenmesi, Destek vektör makineleri, Dalgacık dönüşümü, Uzun-kısa süreli bellek

1 Giriş

En yaygın ve yıkıcı doğal afetlerden biri olan kuraklık, insan toplumlarının doğal yaşam alanlarına ve ekosistemlerine önemli zararlar vermektedir [1]. Şiddetli ve kalıcı kuraklıklar tarım, ormancılık, su yönetimi ve enerji üretimi üzerinde ciddi sonuçlara yol açabilir; bu da gıda ve su kıtlığına, biyoçeşitlilik kaybına ve toplumsal huzursuzluğa neden olabilir [1, 2]. Kuraklık olaylarının hem sıklığında hem de şiddetinde öngörülen artışın, nispeten

Abstract

Drought, a severe natural disaster that poses a threat to humans and their living environments, is difficult to detect at first and its actual impacts often become noticeable only after they occur. Numerous methods have been proposed to detect, prevent, monitor, and mitigate the effects of drought. Among these, one of the most commonly preferred by researchers is the Standardized Precipitation Evapotranspiration Index (SPEI). Since this method is used for detecting and monitoring droughts, it does not provide any future information. Therefore, techniques such as machine learning are utilized to make future predictions. In this study, future drought prediction models were developed for Edirne, which is located in the western region of Türkiye, and these models were analyzed using machine learning methods. The Long Short-Term Memory (LSTM) and Support Vector Machine (SVM) were selected as the modeling approaches. Additionally, the cross-correlation method was used to construct four different drought models. SPEI12 data for the period 1901–2023, which are assumed to best represent hydrological droughts, were employed in the analysis. The Wavelet Transform (WT) was also used to improve model performance. To evaluate the model results, several performance metrics were utilized, including the Correlation Coefficient (r), the Root Mean Square Error (RMSE), the Nash–Sutcliffe Efficiency (NSE), the Kling–Gupta efficiency (KGE), and the Performance Index (PI). The findings revealed that the WT-based SVM02 (SVMWM02) model produced the best results. Therefore, this model should be used in future drought modeling studies for Edirne.

Keywords: Drought, Machine learning, SVM, Wavelet transform, LSTM

ılımlı küresel ısınma koşullarında bile, popülasyonların ve arazi kullanımının kuraklığa karşı hassasiyetini önemli ölçüde artırması beklenmektedir [3]. Vicente-Serrano vd. [4] de gelecekteki iklim değişikliği senaryolarının küresel ölçekte kuraklığın şiddetinin artacağını gösterdiğini desteklemekte ve çeşitli çevresel sistemlerin hassasiyetinin değişebileceğini ve yapısal kuraklık etkilerinin görülme sıklığının artabileceğini eklemektedir. Ayrıca, Wang vd. [5] tarafından vurgulandığı üzere, kuraklık bitki örtüsünün

* Sorumlu yazar / Corresponding author, e-posta / e-mail: turker42@hotmail.com (T. Tuğrul)

Geliş / Received: 08.11.2025 Kabul / Accepted: 10.12.2025 Yayınlanma / Published: 15.01.2026

doi: 10.28948/ngumuh.1819926

büyümesi için önemli bir sınırlayıcı faktör olarak belirtilmektedir. Dahası, Afet Epidemiyolojisi Araştırma Merkezi'ne (CRED) göre, aşırı sıcaklık olayları son yirmi yılda afet kaynaklı küresel insan ölümlerinin %13'ünü oluşturmuştur. Aynı raporda ayrıca, bu dönemde sellerin ve kuraklığın sırasıyla yaklaşık 1.65 milyar ve 1.45 milyar kişiyi etkilediği belirtilmektedir [6].

Yaban hayatı habitatlarının ve tarımın zarar görmesi, sosyo-ekonomik sürdürülebilirlik ve insan refahı, kuraklığın doğrudan ve dolaylı etkilerinden yalnızca bazılarıdır [7, 8]. Kuraklıklar ve diğer düşük yağışlı dönemler, hidroelektrik santralleri için de ciddi sonuçlar doğurabilir [9, 10]. Ayrıca, kuraklık olayları, sıcak hava dalgaları gibi ilişkili tehlikelerin ortaya çıkışını daha da etkileyebilir ve bu tür olayların birleşmesi orman yangını riskini artırabilir [11]. Bu nedenle, etkili planlama ve yönetim için kuraklığın mekansal ve zamansal örüntülerini takip etmek ve anlamak esastır [12]. Kuraklık sadece bilim insanlarının değil aynı zamanda yaşayan herkesin takip etmesi ve önlem alması gereken bir doğal felakettir. Bu yüzden, kuraklık izleme ve tahmini, etkili kuraklık risk yönetimi ve erken uyarı sistemlerinin geliştirilmesi için esastır. Kuraklık koşullarını izlemek ve değerlendirmek için yaygın olarak kullanılan standartlaştırılmış göstergeler mevcuttur. Yalnızca yağış verilerine dayanan hesaplama yöntemiyle SPI ve kuraklık şiddetinin daha kapsamlı bir değerlendirmesini sağlamak için evapotranspirasyonu (buharlaşma-terleme) da içeren SPEI, bu göstergelerin bazı örnekleridir [13, 14].

Türkiye, de içinde bulunduğu Akdeniz bölgesinde yer almakla beraber kuraklıklar için kalıcı ve önemli bir endişe kaynağıdır. Değişen kuraklık özelliklerini ve yoğunlaşan etkilerini belgeleyen çok sayıda çalışma mevcuttur [15, 16]. Gözlemler ve iklim projeksiyonları, Akdeniz'in 21. yüzyıl boyunca giderek artan sıklıkta ve şiddette kuraklık koşulları yaşamasının muhtemel olduğunu göstermektedir; nitekim son on yılda kıta, Avrupa'sına kıyasla güney Akdeniz'de şimdiden uzun süreli kuraklık koşulları yaşandığını göstermektedir [15].

Kuraklık mahsul verimini, hidrolojik süreçleri ve toprak-su dengelerini önemli ölçüde etkileyebildiğinden, bu tür eğilimlerin tarım ve su kaynakları üzerinde derin/temel etkileri vardır. Dolayısıyla, kuraklıkların önceden tespiti son derece önemlidir. Literatürde artık kuraklıkların sadece tespit edilmesi, izlenmesi, takip edilmesi değil, aynı zamanda ileriye yönelik tahminleri ile ilgili çalışmalar da mevcuttur. Kuraklıkların ileriye yönelik tahmin edilmesinde araştırmacılar çeşitli yöntemlere başvurmaktadır. İleriye yönelik tahminlerin başında stokastik yöntemler, makine öğrenme teknikleri ve derin öğrenme teknikleri gelmektedir [17]. Her ne kadar stokastik yöntemler ile hala etkili sonuçlar alınsa da, bu yöntem yerini makine öğrenme tekniklerine bırakmıştır. Hatta, bunlarında ötesinde olan optimizasyon tekniklerinden de çoğu araştırmacı yararlanmaktadır [18]. Tüm bu teknikler, kuraklıkların tahmin edilmesi ve/veya ileriye yönelik hidrolojik ya da meteorolojik parametrelerin tahmin edilmesinde araştırmacıların vazgeçilmez araçları olmuştur.

Kuraklık olgularının tahmin edilmesinde artan karmaşıklığına yanıt olarak, makine öğrenimi teknikleri

güçlü araçlar olarak ortaya çıkmış ve kullanılmaya başlanmıştır [19-21]. Yapay Sinir Ağları (ANN), LSTM, SVM ve Rastgele Orman (RF) gibi algoritmaları içeren bu yöntemler, zaman serisi verileri içindeki doğrusal olmayan ve karmaşık ilişkileri etkin bir şekilde modelleyebilir ve özellikle söz konusu büyük veriden bilgi çıkarımı olduğunda, geleneksel istatistiksel yaklaşımlardan daha iyi performans göstermektedir. Bu algoritmaların üstün performansı yapılan çalışmalar ile literatürde kanıtlanmış ve bu konu ile ilgilenen herkesin dikkatini çekmiştir. Bunlardan bazıları; Tuğrul ve Hınıs [22] Konya Kapalı Havzasında bulunan Apa Barajı bölgesinde aylık yağış verisi ile önce kuraklıkları farklı zaman adımlarında hesaplamışlar ardından bu veriyi makine öğrenme yöntemlerinde kullanarak farklı modeller geliştirmişlerdir. Kullandıkları makine öğrenme yöntemlerinde SVM, RF, ANN ve Karar Ağaçları (DT) yer almaktadır. Bunlara ilave olarak elde ettikleri modellerin performansını artırmak için WT kullanmışlardır. Elde ettikleri sonuçlarda SVM'nin üstün performans sergilediğini söylemişlerdir. Bir diğer çalışma ise, Devanand vd. [23], muhtemelen insan kaynaklı iklim değişikliğiyle şiddetlenmiş aşırı bir olay olan Avustralya'daki 2017-2019 kuraklığını, yani 'Tinderbox Drought' olarak adlandırılan olayı analiz etmek için açıklanabilir bir makine öğrenimi yöntemi kullanmıştır. İlgili iklim koşullarıyla kuraklık etkilerini ortaya çıkarmak ve çeşitli iklim faktörlerinin kuraklık şiddetini nasıl belirlediğine dair daha net bir öngörü sağlamak amacıyla bir hasar fonksiyonu oluşturmak için RF algoritmasını uygulamışlardır. Bir başka çalışmada, Pande vd. [24], SPI ve meteorolojik kuraklık koşullarını tahmin etmek için ANN ve M5P model ağaçlarını uygulamıştır. Bulguları, iklimle ilgili olayların tahmin edilmesinde makine öğrenimi tabanlı modellerin doğruluğunu ve faydalarını vurgulamıştır. Diğer araştırmacılar da çeşitli makine öğrenimi yaklaşımlarını keşfetmişlerdir. Örneğin, Zhao vd. [25], SPEI ile kuraklık koşullarını izlemek için çok kaynaklı uzaktan algılama verileriyle birleştirilmiş SVM kullanan veri odaklı bir çerçeve geliştirmiştir. Bir diğer çalışma ise, Achite vd. [26], Vadi Mina Havzası'nda (Cezayir) beş istasyondan elde edilen verileri ve farklı zaman adımlarındaki (1, 3, 6, 9 ve 12 aylık) Standartlaştırılmış Akış İndeksi (SRI) kullanarak hidrolojik kuraklığı tahmin etmek için Aşırı Makine Öğrenmesi (ELM) ve WT ile hibritleştirilmiş ELM (ELMW) kullanmıştır. Bulgular, ELMW modelinin Cezayir'de güvenilir kuraklık tahmini için kullanılabileceğini göstermiştir.

Literatürdeki çalışmalardan da anlaşılabileceği gibi, makine öğrenme yöntemleri ile etkili kuraklık tahminleri yapılabilmektedir. Kullanılan algoritmaların performansı çalışılan bölgeye göre değişiklik gösterse de, performansı düşük olan model ya da algoritmaların performansı çeşitli yöntemler ile artırılabilir. Genellikle araştırmacılar WT'yi model performansını artırmak için kullanmakta ve başarılı sonuçlar elde ettiği raporlanmaktadır.

Tüm bunlardan yola çıkarak, Türkiye'nin Trakya bölgesinde yer alan ve bölgenin en önemli şehirlerinden birisi olan Edirne için bu çalışmada ileriye yönelik kuraklık tahmin modellerinin performansı araştırılmıştır. Bölgeden

elde edilen SPEI verisiyle cross-correlation yöntemi ile 4 farklı model girdileri oluşturulmuş, SVM ve LSTM yöntemleri ile bu modeller analiz edilmiştir. Son olarak da elde edilen model sonuçları WT ile güçlendirilmiştir. Literatür çalışmaları incelendiğinde daha önceden bu bölge için SVM ve LSTM ile herhangi bir araştırma yapılmamış olması dikkat çekmiş ve literatürde bu konu ile alakalı bir boşluk olduğu kanaatine varılmış, bu çalışma ile bu boşluğun doldurulması amaçlanmıştır. Daha önceden herhangi bir kuraklık çalışması yapılmamış olan Edirne için geliştirilen modeller, bölgedeki su kaynaklarının planlanmasında, kuraklıklara karşı alınacak olan önemlerde ve tarımsal politikaların geliştirilmesinde karar verici mercilere yardımcı olacaktır.

2 Materyal ve metot

2.1 Çalışma alanı

Çalışma alanı olan Meriç-Ergene Havzası (yaklaşık 40°30'–42°30' K ve 25°30'–28°00' B), Türkiye'nin toplam yüzölçümünün yaklaşık %3.5'ini oluşturan yaklaşık 27.500 km²'lik (Türkiye kısmı) bir alanı kaplar. Havza, Türkiye'nin kuzeybatısında, Marmara Bölgesi'nin Trakya kesiminde yer alır ve ülkenin Avrupa kıtasındaki topraklarını oluşturur. Güneyden Marmara Havzası ile komşu olup, kuzeyde Bulgaristan ve batıda Yunanistan ile ulusal sınırları paylaşır. Havza sınırları içerisinde Edirne, Kırklareli ve Tekirdağ illerinin büyük bir bölümü bulunmaktadır. Bölgenin rakımı deniz seviyesinden yaklaşık 1031 m'ye (Yıldız Dağları'na) kadar değişmekte olup, ortalama rakım 150 m civarındadır. Havzanın en belirgin topoğrafik yapıları, kuzey sınırını oluşturan Yıldız (Istranca) Dağları ve havza çekirdeğini oluşturan geniş Ergene düzlükleridir. Havza, sınır aşan bir hidrolojik yapıya sahiptir. Ana su kütlesini Meriç Nehri ve onun ana kolları olan Ergene, Tunca ve Arda nehirleri oluşturur. Bu nehir sistemi, sularını Saros Körfezi üzerinden Ege Denizi'ne boşaltır. Havza aynı zamanda Gala Gölü Milli Parkı, Enez ve Dalyan lagünleri gibi uluslararası öneme sahip sulak alanlara ve su depolama yapılarına ev sahipliği yapmaktadır. Bölgede, karasal Balkan iklimi ile Akdeniz iklimi arasında bir geçiş iklimi hüküm sürer. Bu durum yazların sıcak ve kurak, kışların ise soğuk ve yağışlı (zaman zaman kar yağışlı) geçmesine neden olur. Havza geneli yıllık ortalama yağış miktarı yaklaşık 550–600 mm olup, yağışlar daha çok kış aylarında yoğunlaşır. Yıllık ortalama sıcaklık ise yaklaşık 13-14°C seviyelerindedir. Meriç-Ergene Havzası, Türkiye'nin en önemli tarımsal üretim alanlarından biri olması (özellikle ayçiçeği ve çeltik tarımı), stratejik konumu ve maruz kaldığı hidrolojik değişkenlikler (taşkın/kuraklık) nedeniyle ekolojik ve ekonomik açıdan büyük öneme sahiptir. Havza içerisinde bulunan Edirne, bölgenin en gelişmiş ili olup bu çalışmanın çalışma alanı olarak seçilmiştir (Şekil 1).

2.2 Veri seti

Edirne bölgesi için ileriye yönelik kuraklık tahmin modellerinin araştırıldığı bu çalışmada 1901-2023 yılları arasındaki aylık SPEI verileri kullanılmıştır. Bu veri internet üzerinden yani, Küresel SPEI veri tabanından hazır olarak temin edilmiş ve 12 aylık zaman adımı tercih edilmiştir. 12

aylık zaman adımının tercih edilmesinin sebebi, hidrolik kuraklıkları daha temsil etmesidir [22].

Model performanslarının derinlemesine araştırılması amacıyla cross-correlation yöntemiyle elde edilen veriler kullanılarak farklı model girdi yapıları oluşturulmuştur. Bu yöntemden elde edilen sonuçlar Şekil 2'de gösterilmiştir. Bu yöntem sayesinde çıktı değerini en iyi şekilde tahmin edebilmek için, girdi verisinin ne kadar geciktirileceği bulunabilmektedir.

Cross-correlation yöntemine göre çıktı değeri için en etkili olabilecek veri t-1 zamanına ait geciktirilmiş olan değerdir. M01 ve diğer modellerin hepsine bu veri eklenmiştir. Ayrıca, tahmin değerine etki edebilecek diğer tüm değerler de farklı modellerin girdi yapısında kullanılmıştır. Sonuç olarak oluşturulan tüm modeller Tablo 1'de gösterilmiştir.

Tablo 1. Cross-correlation sonuçlarına göre oluşturulan modeller

Model	Geciktirilmiş değerler SPEI12					Çıktı
M01	t-5	t-4	t-3	t-2	t-1	t
M02		t-4	t-3	t-2	t-1	t
M03			t-3	t-2	t-1	t
M04				t-2	t-1	t

2.3 Standartlaştırılmış yağış evapotranspirasyon indeksi (SPEI)

Bölgenin iklim ve çevre koşullarına bağlı olarak uygun kuraklık göstergelerinin seçilmesi önemlidir. Örneğin, SPI kuraklığın öncelikli olarak yağış eksikliğinden kaynaklandığı bölgeler için uygundur; SPEI ise sıcaklık değişimlerinin de önemli bir rol oynadığı bölgelerde daha iyi performans gösterir. Sıcaklık değişkenliğinin dahil edilmesi, SPEI'yi iklim değişikliği bağlamında özellikle önemli hale getirir.

Nispeten yeni bir meteorolojik kuraklık endeksi olan SPEI, SPI'nin güçlü yönlerini bünyesinde barındırırken aynı zamanda sıcaklık değişkenliğini de hesaba katar. Vicente-Serrano vd. [27] tarafından açıklandığı gibi, SPEI'nin hesaplama süreci, önce her ay için potansiyel buharlaşmanın (PET) belirlenmesini, ardından yağış değerinden (P_i) PET çıkarılarak aylık su dengesi açığının (D_i) hesaplanmasını içerir (Denklem 1).

$$D_i = P_i - PET \quad (1)$$

Bu süreç, SPEI'nin hem yağış hem de sıcaklık etkilerini hesaba katabilmesini sağlar ve bu da onu değişen iklim koşulları altında kuraklık izleme için daha uygun hale getirir [28]. Hao ve Singh [29], Haro-Monteagudo vd. [30] ve Wahla vd. [31] gibi ek kaynakların dahil edilmesi, analizin güvenilirliğini ve hesaplanabilirliğini artırır.

SPEI hesaplamaları, log-lojistik dağılımı standart bir normal dağılıma dönüştürerek SPI'dakiyle aynı temel adımları izler. Yöntemin ayrıntıları için Vicente-Serrano vd. [27] çalışmasına bakılabilir.

PET değerleri, SPI yöntemini SPEI yönteminden ayıran en önemli parametredir. D_i hesaplaması için yağışa ek olarak gerekli olan PET değerinin hesaplanması, sonuçları

doğrudan etkileyebilir. PET hesaplamalarında en doğru sonuçları veren FAO-56 Penman-Monteith (PM) yöntemi kullanılır. FAO56-PM, Allen vd. [32] tarafından şu şekilde sunulmuştur (Denklem 2):

$$ET_{pm} = \frac{0.408 * \Delta * (R_n - G) + \gamma * [900 / (T + 273)] * U_2 * (e_s - e_a)}{\Delta + \gamma(1 + 0.34U_2)} \quad (2)$$

Burada; ET_{pm} buharlaşmayı, Δ doymuş buhar basıncı fonksiyonunun eğimi, γ psikometrik sabiti, R_n net radyasyonu, G toprak ısı akışı yoğunluğunu, U_2 yerden 2 m yükseklikteki rüzgar hızını, T ortalama sıcaklığını temsil etmektedir. Ayrıca bu analizde kullanılan tüm değerler, modellerde kullanılmadan önce normalize edilmiştir (Denklem 3).

$$D = \sum_{i=1}^k \frac{N_i - \bar{N}}{N_{max} - N_{min}} \quad (3)$$

2.4 Destek vektör makinesi (SVM)

SVM, Boser vd. [33] tarafından geliştirilmiştir ve sınıflandırma ve regresyon görevlerinde yaygın olarak kullanılmakta olup, istatistiksel öğrenme teorisine dayalı hidroloji ve diğer alanlarda tahmin edilen doğruluğu önemli ölçüde artırmaktadır. SVM, birden fazla yanıt üretebilen diğer algoritmaların aksine, belirli bir veri kümesi için tekil, optimum bir çözüm sağlayarak kendini farklılaştıran bir gözetimli öğrenme teknolojisidir. Bu özellik, SVM'yi doğrusal olmayan senaryolarda karar sınırlarını belirlemek için bir çekirdek işlevi kullanarak aşırı uyumu azaltmada oldukça yetenekli hale getirir [18].

SVM, makine öğreniminde çekirdek tabanlı bir sınıflandırıcıdır. Bu öğrenme sistemi, veri uygunluk fonksiyonunu sınıflandırmak ve tahmin etmek için kullanılır ve veri kategorizasyonundaki veya uygunluk fonksiyonunun kendisindeki hataları en aza indirmeyi hedefler. Doğrusal veri sınıflandırmasında amaç, daha sağlam bir mesafeye (marja) sahip bir çizgi belirlemektir [34].

Uyarlanabilirliği ve etkinliği sayesinde SVM hem regresyon hem de sınıflandırmada yaygın olarak kullanılmakta, bu da onu makine öğreniminde önemli bir yöntem haline getirmektedir. Ayrıca, bu yöntem çok sayıda başarılı uygulamaya sahiptir [35, 36].

Regresyon sorunları bağlamında SVM, Destek Vektör Regresyonu (SVR) olarak adlandırılabilir [37]. SVM'nin temel amacı istatistiksel öğrenme hatalarını azaltmak ve dolayısıyla modelin öngörülebilirliğini ve sağlamlığını artırmaktır [38]. Gunn [39], Vapnik [40] ve Panahi vd. [41], destek vektör regresyonunun arkasındaki teoremin kısa bir açıklamasını sunar.

SVM modellerinin etkinliği, doğrusal, polinom, radyal baz fonksiyonu, sigmoid veya Gauss fonksiyonu dahil olmak üzere çekirdek fonksiyonunun seçimine bağlıdır. Bu çalışmada, model performansı üzerindeki önemli etkisi nedeniyle Gauss çekirdeğini seçilmiştir. Üç kritik parametre, modelin Gauss çekirdeğiyle performansını doğrudan etkiler: Belayneh vd. [42] tarafından belirtildiği gibi ölçek parametresi (γ), düzenleme sabiti (C) ve epsilon (ϵ).

Parametreler, modelin etkinliğini artırmak için MATLAB'da otomatik olarak ayarlanmıştır.

SVM'nin matematiksel formülasyonu, giriş ve çıkış değişkenleri arasındaki ilişkiyi tanımlayan Denklem (4)'te sunulmuştur:

$$f(x) = (w, \phi(x)) + b \quad (4)$$

Burada $f(x)$ yüksek boyutlu bir özellik uzayını, w çıktı değişkeninin ağırlığını ve b ön tahmin değeri terimini ifade eder.

2.5 Uzun-kısa süreli bellek (LSTM)

Son yıllarda, derin öğrenme, özellikle görüntü sınıflandırma ve zaman serisi tahmini gibi alanlarda kendi alanında önemli ilerlemeler kaydetti. Tekrarlayan Sinir Ağı (RNN) modelinin evrimi/geliştirilmesi olan LSTM modeli, geleneksel RNN'lerde yaygın olan kaybolan gradyanlar sorununu etkili bir şekilde ele alır. LSTM, Hochreiter ve Schmidhuber [43] tarafından önerildiği gibi, bilgileri uzun zaman aralıklarında işlemesine olanak tanıyan mekanizmalar ekleyerek bunu başarır. LSTM'nin gücü, bellek hücreleri ve çeşitli kapılar gibi geliştirilmiş bellek bileşenleri aracılığıyla uzun süreli veri dizilerini koruyabilme yeteneğinde yatar ve bu da onu standart RNN'lere kıyasla uzun süreli dizileri işleme konusunda daha verimli hale getirir [44].

Bir LSTM ağının mimarisi, zaman serisi verilerini ağa beslemek için gerekli olan bir sıra girişi (SI) katmanını içerir. Bu katman bir giriş kapısı, bir unutma kapısı, kendi kendini yineleyen bağlantısı olan bir hücre ve bir çıkış kapısı içeren birimlerden oluşan LSTM katmanına bağlanır. Bu bileşenler, gerektiğinde eklenerek veya çıkarılarak bilgileri topluca yönetir. Bu, Hochreiter ve Schmidhuber [43] tarafından önerilen bir kavramdır. LSTM parametrelerini optimize etmek ve kayıp fonksiyonunu en aza indirmek için Stokastik Gradyan İnişi (SGD), Kök Ortalama Kare Yayılımı (RMSProp) ve Uyarlanabilir Anlar (Adam) gibi çeşitli algoritmalar kullanılabilir. RNN'lere benzer şekilde, LSTM'ler, $t=l$ 'den $t=\tau$ 'ya kadar aşağıdaki denklemleri kullanarak ağ birimi aktivasyonlarını yinelemeli olarak hesaplayarak bir giriş dizisi x 'ten bir çıkış dizisi y 'ye bir işleme hesaplar. Başlangıç değerleri $C_0=0$ ve $h_0=0$ olmak üzere:

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (5)$$

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (6)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (7)$$

$$C_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (8)$$

$$C_t = f_t \otimes C_{t-1} + i_t \otimes C_t \quad (9)$$

$$h_t = o_t \otimes \tanh(C_t) \quad (10)$$

şeklinde. Burada W_i , W_f , ve W_o sırasıyla giriş, unutma ve çıkış kapılarından girişe olan ağırlık matrisini, LSTM ağlarının mimarisinde U_i , U_f ve U_o sırasıyla giriş, unutma ve

çıkış kapılarını gizli katmana bağlayan ağırlık matrislerini, yine sırasıyla b_i , b_f ve b_o ön tahmin değerlerini, h_t ile ilişkili olarak yine sırasıyla i_t , f_t , o_t ve C_t herhangi bir zamandaki hücre durumlarını ifade eder.

2.6 Dalgacık dönüşümü (WT)

Dalgacık dönüşümü literatürde genellikle iki versiyonda sunulur: Sürekli Dalgacık Dönüşümü (CWT) ve Kesikli Dalgacık Dönüşümü (DWT). CWT uygulanmasıyla ilişkili hesaplama karmaşıklıkları nedeniyle, DWT sıklıkla tercih edilir [45]. DWT, sinyal işlemeyi kullanarak zaman serisi verilerini farklı frekans bileşenleri boyunca alt sinyallere ayırarak Fourier dönüşümüne bir alternatif sunar, böylece belirli özelliklerin çıkarılması sağlanır [45]. DWT, zaman alanında bir sinyali parçalamak için matematiksel bir fonksiyon kullanarak sinyalin zaman-frekans analizini sunar. Ayrık dalgacık dönüşümü bir dalgacık fonksiyonu kullanır. Çeşitli frekanslar arasında ayırım yapan "ana dalgacık" olarak adlandırılan dalgacık, çeşitli ölçeklerde işlev görür ve zamana bağlı olarak çalışır. Ana dalgacığın hesaplanması Denklem (11)'de sunulmuştur:

$$\psi_{m,n}(t) = \frac{1}{s_0^m} \psi \left\{ \frac{t - n\tau_0 s_0^m}{s_0^m} \right\} \quad (11)$$

Burada m ve n kontrol parametrelerini, τ_0 geçici konumu, s_0 ölçeği ifade eder.

Ana dalgacık hesaplarından sonra farklı detay seviyelerinde dalgacıklar oluşturulur ve zaman serisi en iyi şekilde ayrıştırılmış olur.

2.7 Performans değerlendirme kriterleri

Model sonuçlarının istatistiksel olarak değerlendirilmesi için, aşağıda belirtilen performans değerlendirme kriterlerinden yararlanılmıştır. Bu kriterler r , RMSE, NSE, KGE ve PI sırasıyla Denklem (12), (13), (14), (15) ve (16)'da ifade edilmiştir.

$$r = \frac{\sum_{i=1}^N [(x)_{pi} - \bar{x}_p] (x_{oi} - \bar{x}_o)}{\sqrt{\sum_{i=1}^N [(x)_{pi} - \bar{x}_p]^2} * \sqrt{\sum_{i=1}^N (x_{oi} - \bar{x}_o)^2}} \quad (12)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_{oi} - x_{pi})^2} \quad (13)$$

$$NSE = 1 - \left[\frac{\sum_{i=1}^N (x_{oi} - x_{pi})^2}{\sum_{i=1}^N (x_{oi} - \bar{x}_o)^2} \right] \quad (14)$$

$$KGE = 1 - \sqrt{(r-1)^2 + 3(a-1)^2 + (\beta-1)^2} \quad (15)$$

$$PI = \frac{\frac{RMSE}{|\bar{x}_p|}}{1+r} \quad (16)$$

3 Bulgular ve tartışma

Edirne bölgesinden temin edilen SPEI12 verisi ile farklı model girdi yapıları oluşturulmuş, ardından bu girdi yapıları LSTM ve SVM yöntemleri ile analiz edilmiştir. Model sonuçlarını daha iyileştirmek için WT her bir modele uygulanmıştır (M01, M02, M03, M04). Analizler gerçekleştirilirken, veri setinin %70'i öğrenme, %30'u da test amacıyla kullanılmıştır. Bu çalışmada, model performansları incelenirken, test verisinden yararlanılmıştır. Analizler sonucunda elde edilen tüm modellere ait sonuçlar Tablo 3'te gösterilmiştir.

Bu tabloya göre, çalışma alanı için LSTM yöntemiyle gerçekleştirilen analizlerde en iyi performans değerleri, M04'te elde edilmiştir. M04'ün model girdi yapısında t-2 ve t-1 zamanlarına ait SPEI12 verisi bulunmaktadır. Diğer model girdi yapılarına göre daha az girdi verisi olmasına rağmen, en iyi performans metrikleri bu modelde elde edilmiştir. LSTM yöntemiyle analizlere WT uygulandıktan sonra da devam edilmiştir. WT'den sonra yapılan analizlerde ise bu kez M02 modeli diğer modellere göre üstünlük sağlamıştır. Bu modelin girdi yapısında ise, t-4, t-3, t-2 ve t-1 zamanlarına ait SPEI12 verisi bulunmaktadır. M04 ile kıyaslandığında, M02'nin girdi yapısında daha çok veri bulunmaktadır. Bu da WT ile yapılan analizlerde girdi yapısında daha çok geciktirilmiş verinin olması analiz sonucunu olumlu yönde etkilemiştir. Her ne kadar M04'de de performans artışları olsa da, M04 performans olarak M02'nin arkasında kalmıştır. Ayrıca analizden sonra tüm modellerin performans metriklerinde artışlar tespit edilmiştir.

Tablo 3. Cross-correlation sonuçlarına göre oluşturulan modeller

LSTM						SVM					
WT'den önce						WT'den önce					
Model	r	NSE	KGE	PI	RMSE	Model	r	NSE	KGE	PI	RMSE
M01	0.9304	0.8623	0.8210	0.9119	0.3707	M01	0.9268	0.8586	0.9035	1.8781	0.3758
M02	0.9325	0.8535	0.4137	0.9394	0.3823	M02	0.9266	0.8579	0.8984	1.8833	0.3768
M03	0.9364	0.8739	0.7324	0.8698	0.3547	M03	0.9260	0.8573	0.9051	1.8879	0.3776
M04	0.9400	0.8769	0.6713	0.8578	0.3504	M04	0.9259	0.8572	0.8697	1.8887	0.3778
WT'den sonra						WT'den sonra					
Model	r	NSE	KGE	PI	RMSE	Model	r	NSE	KGE	PI	RMSE
M01	0.9566	0.8799	0.2403	0.8400	0.3461	M01	0.9973	0.9945	0.9778	0.1764	0.0742
M02	0.9926	0.9851	0.9796	0.2909	0.1221	M02	0.9981	0.9962	0.9927	0.2956	0.0613
M03	0.9794	0.9571	0.9096	0.4961	0.2068	M03	0.9949	0.9897	0.9637	0.4886	0.1012
M04	0.9889	0.9779	0.9574	0.3546	0.1485	M04	0.9921	0.9842	0.9730	0.6067	0.1255

Analizlerde makine öğrenme yöntemlerinden biri olan SVM'den de yararlanılmıştır. Genel olarak SVM ile yapılan analizlerde, WT'den önce tüm modellerin performans metrikleri, LSTM'in gerisinde kalırken, WT'den sonra SVM'den elde edilen sonuçlar LSTM'in önüne geçmiştir. Dolayısıyla, WT'nin SVM'de model performanslarını iyileştirmesi LSTM'ye göre daha fazladır.


SVM'de yapılan analizlerde, hem WT'den önce hem de sonra en başarılı sonuç M02 model girdi yapısı ile elde edilmiştir. Ayrıca, analizlerin tümünden elde edilen sonuçlar arasında en etkili sonuç SVMWM02 yani M02 modelinin dalgacık dönüşümünden sonra alınmıştır. LSTM'de de WT'den sonra en başarılı girdi yapısının M02 olduğu tespit edilmiştir. Sonuç olarak, Edirne bölgesinde bir kuraklık modeli kurulacaksa, M02'nin girdi yapısı örnek olarak alınmalıdır.

Tüm analizlerden elde edilen istatistiksel sonuçlar yukarıdaki Tablo'da verilmiştir. İstatistiksel sonuçlara ilave olarak, modellerin daha iyi kıyaslanabilmesi amacıyla görsel kıyaslama yöntemlerine de başvurulmuştur. Bu kapsamda, Şekil 3'te LSTM ve Şekil 4'te SVM'ye ait analiz sonuçları violin grafikleri ile gösterilmiştir. Şekil 3 incelendiğinde, gözlem değerleri ile şekilsel olarak en benzer sonuç gösteren model LSTMWM03'dür. Diğer WT ile yapılan analizlerde gözlem değerleri ile benzerlik gösterse de, özellikle mean, median ve extreme değerler göz önünde bulundurulursa bu modelin diğer modellerden farkı daha belirgin olmaktadır. Şekil 4'te de gözlem değerleri ile şekilsel olarak en benzer model SVMWM02'dir. Diğer modeller ile kıyaslandığında, buradaki farklılıklarda çok az olmasına rağmen, özellikle Kernel yoğunlukları, mean, median ve extreme değerleri farklılıkları belirginleştirmektedir. Bu şekillerde ve bundan sonraki tüm şekillerde LSTM01; LSTM algoritması ile M01 modelini, LSTMWM01; LSTM algoritması ile M01 modelinin WT'den sonrasını, SVM01; SVM algoritması ile M01 modelini, SVMWM01'i, SVMWM01; SVM algoritması ile M01 modelinin WT'den sonrasını vb. temsil etmektedir


Şekil 5 makine öğrenme yöntemlerine ait analiz sonuçlarını Taylor grafiğinde sunmaktadır. Bu grafik incelendiğinde, LSTM için gözlem değerlerine en yakın sonuç LSTMWM02'de alınmıştır. Bu da LSTMWM02'yi LSTM'de en başarılı model yapmaktadır. SVM ile yapılan analizlerde gözlem değerlerine en yakın sonuç SVMWM02'de alınmıştır. SVM için oluşturulan grafikte WT ile yapılan sonuçlarda modeller her ne kadar üst üste olsa da, SVMWM02'nin gözlem değerine en yakın sonuç verdiği tespit edilebilmektedir. Dolayısıyla, bu yöntemde de en başarılı model SVMWM02'dir. Tüm buradan elde edilen sonuçlar ile istatistiksel sonuçlar birbiriyle örtüşmektedir

Bu çalışmada kullanılan bir diğer kıyaslama yöntemi de Ridge grafiğidir. Her iki yöntemden elde edilen sonuçlara göre çizilen Ridge grafikleri Şekil 6'da gösterilmiştir. Ridge grafikleri genellikle extreme noktaların ya da extreme tahmin değerlerinin daha net bir şekilde ortaya konulmasında etkili olmaktadır. Dolayısıyla, bu grafikte gözlem değerleri ile model benzerlikleri extreme değerler üzerinden değerlendirilebilir. LSTM'de gözlem değerlerine en yakın sonuçlar LSTMWM02'de, SVM'de ise SVMWM02'de tespit edilmiştir. Bu modellerdeki tepe değerler, yani extrem değerler gözlem değerleri ile en benzerliği sergilemektedir.


Şekil 7'de tüm modellere ait sonuçlar box-normal grafiğinde gösterilmiştir. Bu grafik yardımıyla gözlem değerlerine bağlı olarak en başarılı model belirlenebilmektedir. Grafik incelendiğinde, LSTM modelleri içerisinde gözlem verilerine en yakın sonuçları LSTMWM02 modelinin ürettiği saptanmıştır. Benzer bir biçimde, SVM modelleri arasında ise SVMWM02 modeli en başarılı sonucu vermiştir. Özellikle grafik üzerindeki medyan ve ortalama değerleri en başarılı modelleri belirlerken etkili olmuştur. Ayrıca, modellerdeki extrem değerlerin gözlem değerleri ile olan benzerlikleri de buna katkı sağlamıştır. Buradan elde edilen sonuçlar ile istatistiksel sonuçlar birbiriyle örtüşmektedir



Şekil 5. Tüm modellere ait analiz sonuçlarının Taylor diyagramında gösterilmesi



Şekil 6. Tüm modellere ait analiz sonuçlarının Ridge diyagramında gösterilmesi




Şekil 7. Tüm modellere ait analiz sonuçlarının Boc-normal diyagramında gösterilmesi


Şekil 8’de LSTM yöntemiyle elde edilen bulgular arasında en başarılı model olan LSTMWM02 ile gözlem değerlerinin zaman serisinde kıyaslanması verilmiştir. Şekil incelendiğinde, başlangıç tarihleri ve 1997-1999 yılları arasındaki tahminler haricinde genellikle gözlem değerleri ile uyumlu gittiği belirlenmiştir. Zaman serisindeki ekstrem değerleri, LSTM’in oldukça iyi tahmin ettiği bulunan bir diğer sonuçtur. Saçılma diyagramı da bunu destekler niteliktedir. Şekil 9’da ise, SVM yönteminde en başarılı olan modelin gözlem değerleri ile kıyaslanması zaman serisinde gösterilmiştir. Burada, SVMWM02 modelinin gözlem değerlerini mükemmelde yakın biçimde tahmin ettiği belirlenmiştir. Başlangıç değerlerindeki ekstrem değerler haricinde, tahmin modeli ile gözlem değerleri seri boyunca neredeyse üst üstedir. Saçılma diyagramı ise adeta düz bir doğru şeklindedir. Buradan da anlaşılıyor ki, WT’den sonra SVM, LSTM’e göre daha iyi performans sergilemiştir.

Bu çalışmada, Edirne bölgesinden elde edilen SPEI12 verisinden yararlanılarak ileriye yönelik kuraklık tahmin

modellerinin performansı araştırılmıştır. Analizlerde 4 farklı girdi yapısı kullanılmış, LSTM ve SVM makine öğrenme tekniklerinden yararlanılmıştır. Veri setinin %70’i öğrenme, %30’u da test amacıyla belirlenmiştir. Bu çalışmadan elde edilen bulgular ile literatürdeki farklı çalışmalardan söylenen bulgular birbiriyle örtüşmektedir. Bunlardan bazıları: Tuğrul ve Hınıs [22] yaptıkları çalışmada Konya Kapalı Havzasında yer alan Apa Barajı bölgesinde kuraklık tahmin modelleri oluşturmuş, arından bu modellerin performanslarını araştırmışlardır. Analizlerinde ANN, SVM, RF ve DT’yi tercih etmişler, elde ettikleri sonuçları WT ile güçlendirmişlerdir. Farklı model girdi yapıları oluşturarak analiz sonuçlarını zenginleştirmişler ve elde ettikleri bulgularda SVM’nin diğer yöntemlere göre daha iyi sonuçlar verdiğini dile getirmişlerdir. Bu çalışmada da, WT’den sonra SVM en iyi sonucu veren algoritma olmuştur. Makine öğrenme yöntemleri geçmişten günümüze kadar araştırmacıların sıklıkla tercih ettiği ileriye yönelik model tahminlerinde kullanılan yöntemlerden birisidir.



Şekil 8. LSTM’de en başarılı model olan LSTMWM02’in zaman serisinde gösterimi ve saçılma diyagramı



Şekil 9. SVM’de en başarılı model olan SVMWM02’in zaman serisinde gösterimi ve saçılma diyagramı

SVM ve ANN gibi kullanılan geleneksel yöntemlerin yanı sıra, LSTM gibi son zamanlar geliştirilen yöntemlerde artık araştırmaların odağında yer almaktadır. Bunun gibi yeni yöntemler kendi başlarına kullanıldığı gibi, veri ön işleme yöntemleri ve optimizasyon teknikleri gibi teknikler ile beraber de kullanılabilir. Örneğin, Yusuf vd. [46] Nijer’de ileriye yönelik kuraklık tahmin modeli çalışması yapmışlardır. Onlar çalışmasında LSTM’den yararlanmışlar ve bu çalışmada olduğu gibi veri ön işleme yöntemi olarak WT’yi tercih etmişlerdir. Bulgularında, LSTM ile oluşturulan modellerin iyi sonuçlar verdiğini dile getirmişlerdir. Citakoğlu ve Coşkun [47], Sakarya’da 1960 ile 2020 yılları arasında meteorolojik verilerle Gaussian Süreci Regresyonu (GPR), ANN ve Uyarlanabilir Nöro-Bulanık Çıkarım Sistemi (ANFIS) makine öğrenme algoritmaları kümesini kullanarak kuraklık tahmini üzerine bir çalışma yürütmüşlerdir. Ayrıca, model performansını iyileştirmek için Varyasyon Modu Ayırıştırması (VMD) ve Ampirik Mod Ayırıştırması (EMD) dahil olmak üzere WT’yi

kullanmışlardır. Hibrit GPR modelinin bu çalışmadaki gibi diğer yöntemlerden daha iyi performans gösterdiği sonucuna ulaşmışlardır. Bu çalışmada da WT ile model performans metrikleri iyileştirilmiştir.

Meriç Havzası’nda bulunan Edirne istasyonu için yapılan bu analizler, havzada bulunan diğer istasyonlar için de yapılarak bölgeyi temsil edebilecek bir kapsamlı kuraklık çalışması ortaya konulabilir. Bu bölgede Çorlu ve Lüleburgaz istasyonlarında kuraklıkların varlığı belirli çalışmalarda dile getirilmiştir [48].

4 Sonuçlar

Bu çalışmada, SPEI12 verilerinden yararlanılarak Edirne için kuraklık tahmin modelleri geliştirilmiş ve değerlendirilmiştir. SVM ve LSTM makine öğrenme teknikleri uygulanmış ve model sonuçları WT kullanılarak daha da geliştirilmiştir. Hem istatistiksel hem de grafiksel gösterimleri içeren bu çalışma, derinlemesine bulgular ortaya koymuştur. Başlıcaları;

- WT olmadan yapılan analizlerde SVM performans olarak LSTM'in gerisinde kalmıştır.
- En başarılı model girdi yapısı M02'de tespit edilmiştir. İleriye yönelik projeksiyonlarda bu Edirne için bu girdi yapısı kullanılmalıdır.
- LSTM ve SVM yöntemlerinde WT'nin uygulanmasıyla tüm model performans metriklerinde artışlar kaydedilmiştir.

• WT iki yöntemde de model performans metriklerinin oldukça tatminkar seviyeye getirmiştir. Ama SVM'deki iyileştirme miktarları LSTM'e göre daha fazladır. Yani LSTM ile kıyaslandığında, WT'nin SVM'de uygulanmasıyla daha iyi sonuçlar alınmıştır.

Bu çalışmanın, bölgedeki su kaynakları yönetimi konusunda ilgili kişilere ve bu konulardaki karar verici makamlara yardımcı olacağı düşünülmektedir. Bu konuyla ilgili gelecekte yapılacak projelerde, risk değerlendirmelerinde veya kuraklık önleme çalışmalarında bu çalışmanın yararlanabilir. Bu konu ile çalışan araştırmacılar ileriye yönelik çalışmalarında aşağıdaki önemli noktaları çalışmalarına dahil edebilirler.

- SPEI ötesinde alternatif kuraklık endekslerinin kullanımının araştırılması.
- Bölgedeki meteoroloji istasyonlarının ağını genişleterek veri bulunabilirliğini artırmak ve daha kapsamlı kuraklık modelleme çalışmalarını desteklemek.
- Kuraklık dinamikleri üzerindeki potansiyel etkileri yakalamak için deniz seviyesi ve deniz yüzey sıcaklığı gibi daha geniş bir yelpazede model girdi değişkenlerinin dahil edilmesi.

Teşekkür

Bilim dünyasına katkı sunmak amacıyla ücretsiz bir şekilde veri sağlayan Küresel SPEI veri tabanına teşekkür ederim.

Çıkar çatışması

Yazarlar çıkar çatışması olmadığını beyan etmektedir.

Benzerlik oranı (iThenticate): %3

Kaynaklar

- [1] B. Ghazi, S. Dutt, ve A. Torabi Haghighi, Projection of future meteorological droughts in lake Urmia Basin Iran. *Water*, 15(8),1558, 2023. <https://doi.org/10.3390/w15081558>.
- [2] Y. Gao, X. Li, L. R. Leung, D. Chen, ve J. Xu, Aridity changes in the Tibetan Plateau in a warming climate. *Environmental Research Letters*, 10(3), 034013, 2015. <https://doi.org/10.1088/1748-9326/10/3/034013>
- [3] J. Spinoni et al., Future Global Meteorological Drought Hot Spots: A Study Based on CORDEX Data, (in English). *Journal of Climate*, 33(9),3635-3661, 01 May. 2020 2020. <https://doi.org/10.1175/JCLI-D-19-0084.1>
- [4] S. M. Vicente-Serrano, S. M. Quiring, M. Peña-Gallardo, S. Yuan, ve F. Domínguez-Castro, A review of environmental droughts: Increased risk under global warming?. *Earth-Science Reviews*, 201, 102953, 2020. <https://doi.org/10.1016/j.earscirev.2019.102953>

- [5] T. Wang, X. Tu, V. P. Singh, X. Chen, K. Lin, ve Z. Zhou, Drought prediction: Insights from the fusion of LSTM and multi-source factors. *Science of the Total Environment*, 902, 166361, 2023. <https://doi.org/10.1016/j.scitotenv.2023.166361>
- [6] CRED, Disasters in Numbers 2021. Brussels, Belgium: Centre for Research on the Epidemiology of Disasters (CRED), 2021.
- [7] D. F. Balting, A. AghaKouchak, G. Lohmann, ve M. Ionita, Northern Hemisphere drought risk in a warming climate. *NPJ Climate and Atmospheric Science*, 4(1), 61, 2021. <https://doi.org/10.1038/s41612-021-00218-2>
- [8] J. Yin et al., Future socio-ecosystem productivity threatened by compound drought-heatwave events. *Nature Sustainability*, 6(3),.259-272, 2023.
- [9] K. Forrest, B. Tarroja, F. Chiang, A. AghaKouchak, ve S. Samuelsen, Assessing climate change impacts on California hydropower generation and ancillary services provision. *Climatic Change*, 151(3), 395-412, 2018/12/01 2018. <https://doi.org/10.1007/s10584-018-2329-5>
- [10] J. Laimighofer ve G. Laaha, How standard are standardized drought indices? Uncertainty components for the SPI & SPEI case. *Journal of Hydrology*, 613,. 128385,2022. <https://doi.org/10.1016/j.jhydrol.2022.128385>
- [11] F. Chiang, O. Mazdiasni, ve A. AghaKouchak, Evidence of anthropogenic impacts on global drought frequency, duration, and intensity. *Nature communications*, 12(1), 2754, 2021. <https://doi.org/10.1038/s41467-021-22314-w>
- [12] Y. H. Essa, M. Hirschi, W. Thiery, A. M. El-Kenawy, ve C. Yang, Drought characteristics in Mediterranean under future climate change. *npj Climate and Atmospheric Science*, 6(1), 133, 2023/09/07 2023. <https://doi.org/10.1038/s41612-023-00458-4>
- [13] T. B. McKee, N. J. Doesken, ve J. Kleist, The relationship of drought frequency and duration to time scales. in *Proceedings of the 8th Conference on Applied Climatology*, , 17(22), Boston, 179-183, 1993
- [14] M. Naresh Kumar, C. Murthy, M. Sesha Sai, ve P. Roy, On the use of Standardized Precipitation Index (SPI) for drought intensity assessment, *Meteorological Applications: A journal of forecasting, practical applications, training techniques and modelling*, 16(3), 381-389, 2009. <https://doi.org/10.48550/arXiv.1509.04808>
- [15] T. Caloiero, S. Veltri, P. Caloiero, ve F. Frustaci, Drought analysis in Europe and in the Mediterranean basin using the standardized precipitation index. *Water*, 10(8), 1043, 2018. <https://doi.org/10.3390/w10081043>
- [16] W. M. Kim ve C. C. Raible, Dynamics of the Mediterranean droughts from 850 to 2099 CE in the Community Earth System Model. *Climate of the Past*, 17(2), 887-911, 2021. <https://doi.org/10.5194/cp-17-887-2021>
- [17] T. Tuğrul, S. Oruc, ve M. A. Hınıs, Transforming wind data into insights: A comparative study of stochastic and machine learning models in wind speed

- forecasting. *Applied Sciences*, 15(7), 3543, 2025. <https://doi.org/10.3390/app15073543>
- [18] S. Oruc, T. Tuğrul, ve M. A. Hınıs, Beyond traditional metrics: exploring the potential of hybrid algorithms for drought characterization and prediction in the tromso region, Norway, *Applied Sciences*, 14(17), 7813, 2024. <https://doi.org/10.3390/app14177813>
- [19] W. Almikaeel, L. Čubanová, ve A. Šoltész, Hydrological drought forecasting using machine learning—Gidra river case study, *Water*, 14(3), 387, 2022. <https://doi.org/10.3390/w14030387>
- [20] K. En-Nagre et al., Assessment and prediction of meteorological drought using machine learning algorithms and climate data. *Climate Risk Management*, 45, 100630, 2024. <https://doi.org/10.1016/j.crm.2024.100630>
- [21] C. Lalika, A. U. H. Mujahid, M. James, ve M. C. Lalika, Machine learning algorithms for the prediction of drought conditions in the Wami River sub-catchment, Tanzania. *Journal of Hydrology: Regional Studies*, 53, 101794, 2024.
- [22] T. Tuğrul ve M. A. Hınıs, Improvement of drought forecasting by means of various machine learning algorithms and wavelet transformation. *Acta Geophysica*, 2024/07/01 2024. <https://doi.org/10.1007/s11600-024-01399-z>
- [23] A. Devanand et al., Australia's Tinderbox Drought: An extreme natural event likely worsened by human-caused climate change. *Science Advances*, 10(10), ead3460, 2024. <https://doi.org/10.1126/sciadv.adj3460>
- [24] C. B. Pande et al., Forecasting of SPI and meteorological drought based on the artificial neural network and M5P model tree. *Land*, 11(11), 2040, 2022. <https://doi.org/10.3390/land11112040>
- [25] Y. Zhao et al., Drought monitoring and performance evaluation based on machine learning fusion of multi-source remote sensing drought factors. *Remote Sensing*, 14(24), 6398, 2022. <https://doi.org/10.3390/rs14246398>
- [26] M. Achite, O. M. Katipoğlu, M. Jehanzaib, N. Elshaboury, V. Kartal, ve S. Ali, Hydrological drought prediction based on hybrid extreme learning machine: Wadi Mina Basin Case Study, Algeria. *Atmosphere*, 14(9), 1447, 2023. <https://doi.org/10.3390/atmos14091447>
- [27] S. M. Vicente-Serrano, S. Beguería, J. I. López-Moreno, M. Angulo, ve A. El Kenawy, A new global 0.5 gridded dataset (1901–2006) of a multiscalar drought index: comparison with current drought index datasets based on the Palmer Drought Severity Index, *Journal of Hydrometeorology*, 11(4), 1033-1043, 2010.
- [28] A. Ahmadelipour, H. Moradkhani, ve M. C. Demirel, "A comparative assessment of projected meteorological and hydrological droughts: elucidating the role of temperature. *Journal of Hydrology*, 553, 785-797, 2017. <https://doi.org/10.1016/j.jhydrol.2017.08.047>
- [29] Z. Hao ve V. P. Singh, Drought characterization from a multivariate perspective: A review. *Journal of Hydrology*, 527, 668-678, 2015. <https://doi.org/10.1016/j.jhydrol.2015.05.031>
- [30] D. Haro-Monteagudo, A. Daccache, ve J. Knox, Exploring the utility of drought indicators to assess climate risks to agricultural productivity in a humid climate. *Hydrology Research*, 49(2), 539-551, 2018. <https://doi.org/10.2166/nh.2017.010>
- [31] S. S. Wahla, J. H. Kazmi, A. Sharifi, S. A. Shirazi, A. Tariq, ve H. Joyell Smith, Assessing spatio-temporal mapping and monitoring of climatic variability using SPEI and RF machine learning models. *Geocarto International*, 37(27), 14963-14982, 2022. <https://doi.org/10.1080/10106049.2022.2093411>
- [32] R. G. Allen, L. S. Pereira, D. Raes, ve M. Smith, Crop evapotranspiration-Guidelines for computing crop water requirements-FAO Irrigation and drainage paper 56. Fao, Rome, 300(9), D05109, 1998.
- [33] B. E. Boser, I. M. Guyon, ve V. N. Vapnik, A training algorithm for optimal margin classifiers. in *Proceedings of the fifth annual workshop on Computational learning theory*, 144-152, 1992. <https://doi.org/10.1145/130385.13040>
- [34] E. Shabani, M. A. Ghorbani, ve S. Inyurt, The power of the GP-ARX model in CO₂ emission forecasting. in *Risk, Reliability and Sustainable Remediation in the Field of Civil and Environmental Engineering: Elsevier*, 79-91, 2022
- [35] M. Achite, O. M. Katipoglu, S. Şenocak, N. Elshaboury, O. Bazrafshan, ve H. Y. Dalkılıç, Modeling of meteorological, agricultural, and hydrological droughts in semi-arid environments with various machine learning and discrete wavelet transform. *Theoretical and Applied Climatology*, 154(1-2), 413-451, 2023. <https://doi.org/10.1007/s00704-023-04564-4>
- [36] S. Saha, A. Saha, T. K. Hembram, B. Kundu, ve R. Sarkar, Novel ensemble of deep learning neural network and support vector machine for landslide susceptibility mapping in Tehri region, Garhwal Himalaya. *Geocarto International*, 37(27), 17018-17043, 2022. <https://doi.org/10.1080/10106049.2022.2120638>
- [37] M. Klaus-Robert, M. Sebastian, R. Gunnar, T. Koji, ve S. Bernhard, An introduction to kernel-based learning algorithms. *IEEE TNN*, 2001.
- [38] A. Belayneh, J. Adamowski, B. Khalil, ve B. Ozga-Zielinski, Long-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet neural network and wavelet support vector regression models. *Journal of Hydrology*, 508, 418-429, 2014. <https://doi.org/10.1016/j.jhydrol.2013.10.052>
- [39] S. R. Gunn, Support vector machines for classification and regression. *Technical Report, Image Speech and Intelligent Systems Research Group*, 1997, 1(1), 1-52, 1997.

- [40] V. N. Vapnik, An overview of statistical learning theory. IEEE transactions on neural networks, 10(5), 988-999, 1999.
- [41] M. Panahi, N. Sadhasivam, H. R. Pourghasemi, F. Rezaie, ve S. Lee, Spatial prediction of groundwater potential mapping based on convolutional neural network (CNN) and support vector regression (SVR). Journal of Hydrology, 588, 125033, 2020. <https://doi.org/10.1016/j.jhydrol.2020.125033>
- [42] A. Belayneh, J. Adamowski, ve B. Khalil, Short-term SPI drought forecasting in the Awash River Basin in Ethiopia using wavelet transforms and machine learning methods. Sustainable Water Resources Management, 2(1), 87-101, 2016. <https://doi.org/10.1007/s40899-015-0040-5>
- [43] S. Hochreiter ve J. Schmidhuber, Long short-term memory. Neural computation, 9(8), 1735-1780, 1997.
- [44] T. Mikolov, A. Joulin, S. Chopra, M. Mathieu, ve M. A. Ranzato, Learning longer memory in recurrent neural networks. arXiv preprint arXiv:1412.7753, 2014. <https://doi.org/10.48550/arXiv.1412.7753>
- [45] O. Kisi, Wavelet regression model as an alternative to neural networks for river stage forecasting. Water resources management, 25(2), 579-600, 2011. <https://doi.org/10.1007/s11269-010-9715-8>
- [46] B. Yusuf, A. Shabri, ve R. Rezaie, An innovative hybrid drought modelling approach using wavelet-long-short term memory (W-LSTM) with standardised precipitation index (SPI) data for Badeggi district, Niger State-Nigeria. Discover Applied Sciences, 7(10), 1129, 2025/10/03 2025. <https://doi.org/10.1007/s42452-025-07649-z>
- [47] H. Citakoglu ve Ö. Coşkun, Comparison of hybrid machine learning methods for the prediction of short-term meteorological droughts of Sakarya Meteorological Station in Turkey. Environmental Science and Pollution Research, 29(50), 75487-75511, 2022. <https://doi.org/10.1007/s11356-022-21083-3>
- [48] M. Erişmiş, Standartlaştırılmış yağış buharlaşma indeksine göre Meriç Nehri Havzasında uzun dönem kuraklık analizi. International Journal of Geography and Geography Education, 50, 313-328, 2023. <https://doi.org/10.32003/igge.1297107>

