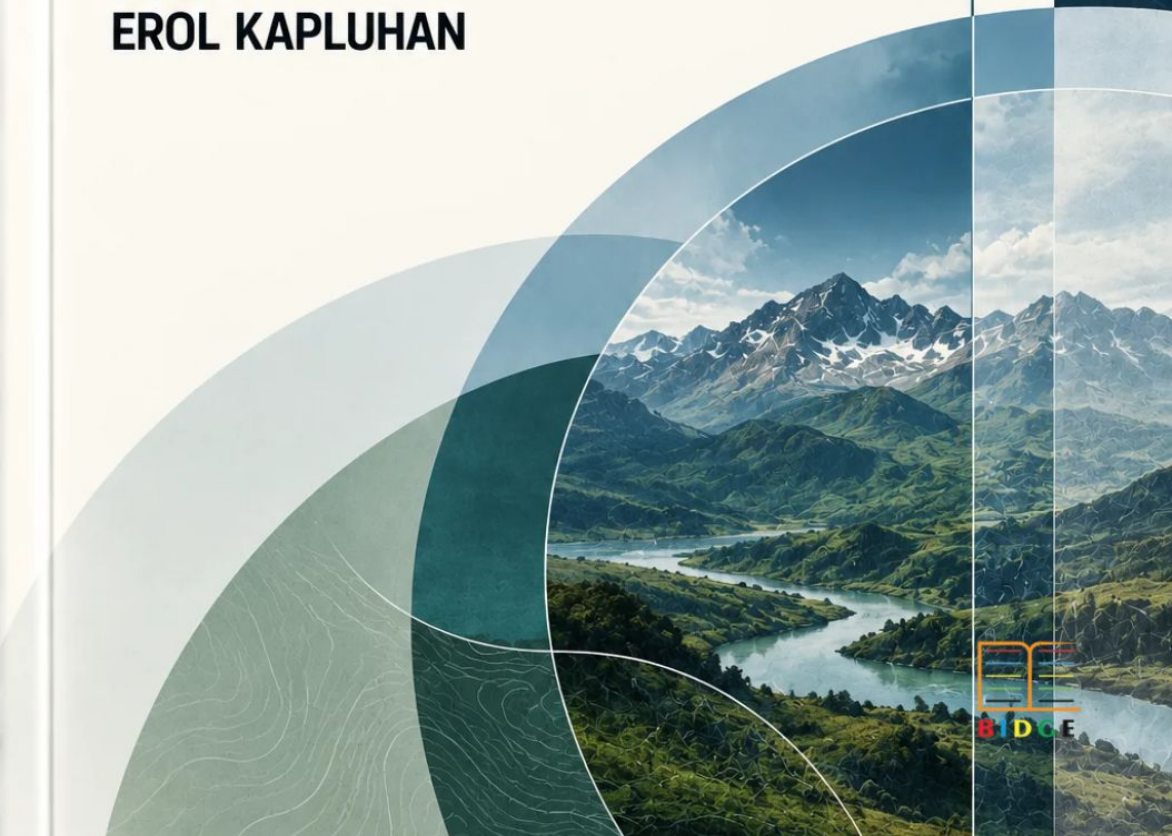
FİZİKİ COĞRAFYA ALANINDA AKADEMİK GÜNCEL ÇALIŞMALAR

Editör:
EROL KAPLUHAN



BİDGE Yayınları

Fiziki Coğrafya Alanında Akademik Güncel Çalışmalar

Editör: Prof. Dr. Erol KAPLUHAN

ISBN: 978-625-5474-68-1

1. Baskı
Sayfa Düzeni: Gözde YÜCEL
Yayınlama Tarihi: 2026-10-25
BİDGE Yayınları

Bu eserin bütün hakları saklıdır. Kaynak gösterilerek tanıtım için yapılacak kısa alıntılar dışında yayıncının ve editörün yazılı izni olmaksızın hiçbir yolla çoğaltılamaz.

Sertifika No: 71374
Yayın hakları © BİDGE Yayınları
www.bidgeyayinlari.com.tr - bidgeyayinlari@gmail.com
Krc Bilişim Ticaret ve Organizasyon Ltd. Şti.
Güzeltepe Mahallesi Abidin Daver Sokak Sefer Apartmanı No: 7/9 Çankaya / Ankara

ÖNSÖZ

Fiziki coğrafya, yeryüzünün doğal ortam özelliklerini, bu ortamı oluşturan unsurlar arasındaki karşılıklı ilişkileri ve doğal süreçlerin zaman ve mekân içerisindeki değişimini konu edinen köklü bir bilim alanıdır. Bununla birlikte, günümüzde yaşanan hızlı çevresel değişimler, iklim sistemindeki dönüşümler, doğal afetlerin artan etkileri, su ve toprak kaynakları üzerindeki baskılar, arazi kullanımındaki değişimler ve insan-doğa etkileşimlerinin giderek karmaşıklaşması, fiziki coğrafyanın yalnızca mevcut doğal yapı ve süreçleri açıklayan bir disiplin olmanın ötesine geçmesini gerekli kılmaktadır. Günümüzde fiziki coğrafya araştırmalarının kapsamı, geleneksel gözlem ve betimleme yöntemlerinin oldukça ötesine ulaşmıştır. Coğrafi Bilgi Sistemleri ve uzaktan algılama teknolojilerinin yaygınlaşması, yüksek çözünürlüklü mekânsal verilerin erişilebilir hâle gelmesi, sayısal modelleme tekniklerinin gelişmesi ve farklı veri kaynaklarının birlikte değerlendirilebilmesi, fiziki coğrafya araştırmalarında önemli bir metodolojik dönüşüm meydana getirmiştir. Bu dönüşüm, doğal süreçlerin yalnızca nerede ve nasıl gerçekleştiğinin belirlenmesine değil; aynı zamanda bu süreçlerin nedenlerinin, değişim eğilimlerinin ve gelecekte ortaya çıkarabileceği olası sonuçların daha ayrıntılı biçimde ortaya konulmasına imkân sağlamaktadır. Bu anlayıştan hareketle hazırlanan “Fiziki Coğrafya Alanında Akademik Güncel Çalışmalar” başlıklı bu eser, fiziki coğrafyanın farklı alt alanlarında yürütülen akademik araştırmaları bir araya getirerek, alanın güncel bilimsel yönelimlerine ilişkin kapsamlı bir değerlendirme sunmayı

amaçlamaktadır. Kitabın temel amacı, fiziki coğrafyanın zengin konu çeşitliliğini ortaya koymanın yanı sıra, güncel araştırma yöntemleri ve yaklaşımları aracılığıyla doğal çevrenin anlaşılmasına yönelik bilimsel çabalara katkı sağlamaktır. Eserde yer alan bölümlerde farklı fiziki coğrafya konuları, çeşitli araştırma soruları ve güncel yöntemler çerçevesinde ele alınırken fiziki coğrafyanın güncel meselelerine ışık tutmakta ve bir bütün olarak değerlendirildiğinde ise alanın farklı dallarını bir arada görme fırsatı sunmaktadır. Bölümlerin konu ve yöntem bakımından gösterdiği çeşitlilik, fiziki coğrafyanın geniş araştırma alanını yansıtmaktadır. Bu yönüyle kitap, yalnızca mevcut bilgilerin derlendiği bir çalışma olmaktan ziyade, fiziki coğrafya alanındaki güncel araştırma eğilimlerinin ve bilimsel yaklaşımların tartışıldığı bir başvuru kaynağı niteliği taşımaktadır. Sonuç olarak Fiziki Coğrafya Alanında Akademik Güncel Çalışmalar kitabının, fiziki coğrafyanın farklı çalışma alanlarına ilişkin güncel araştırmaları bir araya getirerek akademik literatüre katkı sağlamasını, yeni araştırmalar için ilham vermesini temenni ediyoruz. Bu kıymetli çalışmanın hayata geçirilmesinde; yoğun emek ve akademik birikimlerini bizlerle paylaşan tüm bölüm yazarlarına be kitabın basım sürecinde emeği geçen BİDGE Yayınevi ekibine içtenlikle teşekkürlerimi arz ederim.

EDİTÖR

Prof. Dr. Erol KAPLUHAN

25 Ekim 2026

İÇİNDEKİLER

SEL-TAŞKIN DUYARLILIK VE RİSK ANALİZLERİNDE CBS VE YAPAY ZEKÂ KULLANIMI: MEVCUT DURUM VE YÖNTEMSEL EĞİLİMLER 1

KEMAL YURDDAŞ

ORMAN YANGINI SONRASI YANMA ŞİDDETİNİN SPEKTRAL İNDEKSLER VE MAKİNE ÖĞRENMESİYLE ANALİZİ: SEYDİKEMER (MUĞLA) ÖRNEĞİ 43

DUYGU MİNAZ

İÇ ANADOLU'DA KARA–ATMOSFER ETKİLEŞİMİ: TOPRAK NEMİ VE YAZ SICAKLIĞI İLİŞKİSİ 77

FERHAT KESERCİ

DİKİLİ (İZMİR) İSTASYONUNDA İKLİMSEL KURAKLIĞIN UZUN DÖNEMLİ DEĞİŞİMİ: SPI–SPEI KARŞILAŞTIRMASI VE POTANSİYEL EKOLOJİK BASKILAR 106

DİLEK AYKIR, EBRU YEŞİM ÖZKAN, SERKAN KÜKRER

BÖLÜM 1

SEL-TAŞKIN DUYARLILIK VE RİSK ANALİZLERİNDE CBS VE YAPAY ZEKÂ KULLANIMI: MEVCUT DURUM VE YÖNTEMSEL EĞİLİMLER

Kemal YURDDAŞ[1]

Giriş

Küresel ısınma ve iklim değişikliği, küresel ölçekte ekstrem yağış olaylarının sıklığını ve şiddetini artırmakta, hızlı kentleşme sonucu geçirimsiz yüzeylerin artması ve akış alanı daralan drenaj sistemleri bu etkiyi kentsel alanlarda çok daha tehlikeli hâle getirmektedir (Islam vd., 2025). Sel ve taşkınlar, dünya genelinde en çok insanı etkileyen doğal afet türleri arasında yer almaktadır. Uydu verisine dayalı analizler sel ve taşkınlara maruz kalan nüfusun giderek arttığını göstermektedir (Tellman vd., 2021; Rentschler vd., 2022). Kentlerde can kaybının yanı sıra ulaşım ağlarının (Dong vd., 2023) ve raylı sistemlerin (Bi vd., 2024) kesintiye uğraması, ekonomik kayıplar ve sosyal eşitsizliklerin derinleşmesi gibi çok katmanlı sonuçlar ortaya çıkmaktadır (Wing vd., 2022; Tate vd.,

[1] Öğr. Gör. Dr., Manisa Celal Bayar Üniversitesi Demirci MYO Mimarlık ve Şehir Planlama Bölümü, 0000-0003-4691-4038

2021). Bu nedenle sel-taşkın tehlikesinin ve riskinin mekânsal olarak doğru biçimde belirlenmesi, risk azaltma stratejileri açısından büyük önem taşımaktadır (Wang vd., 2022).

Geleneksel yaklaşımlar büyük ölçüde hidrolojik ve hidrolik modellere dayanmaktadır (Guo vd., 2021; Piadeh vd., 2022). Fiziksel temelli bu modeller süreçlerin anlaşılması açısından güçlü olmakla birlikte, ayrıntılı kanal geometrisi, kalibrasyon verisi ve yüksek hesaplama maliyeti gerektirmekte, ölçülmemiş havzalarda ve geniş alanlarda uygulanabilirlikleri sınırlı kalmaktadır (Guo vd., 2021; Yan vd., 2023). Bentivoglio vd. (2022), derin öğrenme modellerinin geleneksel yaklaşımlara kıyasla daha yüksek doğruluk, sayısal modellere kıyasla ise daha yüksek hız sağladığını belirtmiştir. Bu durum, makine öğrenmesi yöntemlerine olan ilgiyi artırmıştır (Anik vd., 2025). Derin öğrenme ve hidrolik modellerin birlikte kullanılması (Kabir vd., 2020), hidrolojik ve hidrolik modellerin makine öğrenmesiyle desteklenmesi (Xu vd., 2023) bu ilgiyi ortaya koymaktadır.

Sel-taşkın duyarlılık analizleri, bir alanın sele ne ölçüde yatkın olduğunu belirlemeyi amaçlamaktadır. Bu analizlerde CBS aracılığıyla yükselti, eğim, akarsuya uzaklık ve arazi örtüsü gibi birçok faktör birlikte değerlendirilirken, uzaktan algılama verileri sel-taşkın alanlarının belirlenmesine katkı sağlamaktadır. Uzman görüşüne dayalı ÇKKV yöntemleri ve istatistiksel yaklaşımlar (Ali vd., 2020; Nagamani vd., 2026), makine öğrenmesi yöntemleriyle karşılaştırılmakta (Vojtek vd., 2021) veya bu yöntemlerle birlikte kullanılmaktadır (Wasie vd., 2026; Rashid vd., 2026). Ayrıca SAR tabanlı görüntü işleme, bulut örtüsünden bağımsız sel-taşkın izleme olanağı sunmaktadır (Amitrano vd., 2024; Misra vd., 2025).

Son yıllarda CBS'nin mekânsal veri yönetimi, çok katmanlı analiz ve görselleştirme kapasitesinin, yapay zekanın (YZ) ise büyük

veriden karmaşık ve doğrusal olmayan örüntüleri öğrenme yeteneğinin birleştirilmesi, CBS–YZ hibrit yaklaşımını literatürde baskın bir paradigma hâline getirmiştir (Lyu vd., 2025; Rezvani vd., 2024; Shirzadi vd., 2025). Uzaktan algılama ürünlerinin açık erişimli hâle gelmesi, bulut tabanlı işlem platformlarının yaygınlaşması ve açık kaynaklı makine öğrenmesi kütüphanelerinin olgunlaşması bu eğilimi hızlandıran temel etkenlerdir. Google Earth Engine'de ölçeklenebilir makine öğrenmesiyle Hint megakentleri için olasılıksal sel-taşkın riski haritalaması (Krishnachaithanya vd., 2025) ve on yıllık uydu radar verisiyle küresel sel-taşkın haritalaması (Misra vd., 2025) bunun örnekleridir. Hibrit çerçeveler yalnızca duyarlılık haritalamasında değil, risk analizlerinde de kullanılmaktadır. Doğal ve insan kaynaklı esnekliği makine öğrenmesi modelleriyle birleştiren kentsel sel-taşkın risk analizi (Zhang vd., 2023), AHP tabanlı tehlike analizini makine öğrenmesi ve açıklanabilir GeoAI ile birleştiren Marmara Bölgesi çalışması (Derman ve Mete, 2025) ve hibrit SVM–XGBoost modeline dayanan bir GeoAI çerçevesi (Aboulola vd., 2026) buna örnek verilebilir.

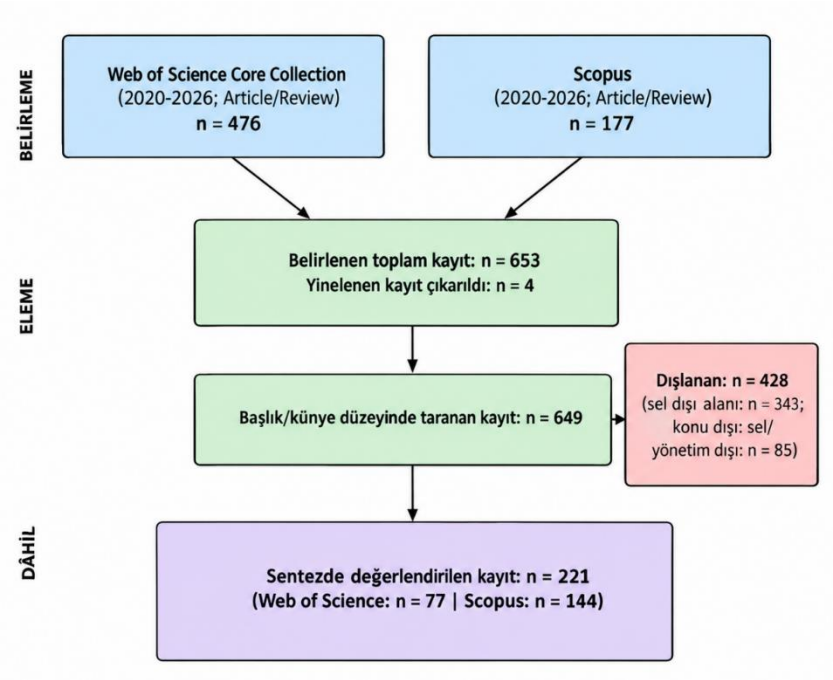
Bu çalışmanın amacı, CBS ve YZ yöntemlerinin sel-taşkın araştırmalarındaki kullanımını eleştirel biçimde değerlendirmek, yöntemsel boşlukları ve sınırlılıkları ortaya koymak ve güncel araştırma eğilimlerini belirlemektir. Web of Science ve Scopus'ta 2020–2026 dönemine ait kayıtlar üzerinden şu sorulara yanıt aranmıştır: (1) CBS ve YZ tabanlı sel-taşkın çalışmaları hangi yöntem, veri kaynağı ve coğrafi bağlamlarda yoğunlaşmaktadır? (2) Duyarlılık ve risk analizlerinde hangi çevresel ve topografik parametreler öne çıkmakta, bunların önemi çalışma bağlamına göre nasıl değişmektedir? (3) Literatürde bildirilen model başarıları, açıklanabilirlik ve doğrulama uygulamaları açısından hangi ortak sınırlılıklar ve gelecek yönelimleri belirginleşmektedir?

1.1. Derleme Yöntemi

Literatür taraması Web of Science Core Collection ve Scopus veri tabanlarında 2020–2026 dönemi, makale (Article) ve derleme (Review) belge türleri için yürütülmüştür. Web of Science taramasından 476, Scopus taramasından 177 kayıt dışa aktarılmıştır. DOI ve başlık eşleştirmesiyle 4 yinelenen kayıt çıkarıldıktan sonra 649 benzersiz kayıt başlık ve künye bilgileri üzerinden değerlendirilmiştir (Şekil 1, Tablo 1). Literatür taraması, 22 Ekim 2026 tarihinde Web of Science Core Collection ve Scopus veri tabanlarında gerçekleştirilmiştir. Aramada flood susceptibility, flood prediction, surfactant flooding, flood inundation, urban flood, flood resilience, urban flooding ve flood mapping anahtar kelimeleri kullanılmıştır. Tarama, 2020–2026 döneminde yayımlanan makale (Article) ve derleme (Review) türündeki yayınlarla sınırlandırılmıştır. Elde edilen kayıtlar, yinelenen yayınların ayıklanmasının ardından çalışma kapsamına uygunluk açısından değerlendirilmiştir.

Literatür içerisinden çalışmalar seçilirken 2 husus dikkate alınmıştır. Birincisi, çalışma sel-taşkın risk, duyarlılık, maruziyet, kırılganlık, esneklik, haritalama, tahmin veya yönetim konularından birini ele almış olmalıdır. İkincisi ise CBS, uzaktan algılama, makine/derin öğrenme veya çok kriterli karar verme yöntemlerini kullanmalı ya da sel-taşkın maruziyeti/ölümleri/yönetimine ilişkin çerçeveleyici bir kaynak olmalıdır. Ayrıca iklim atribüsyonu, buzul gölü taşkınları, paleo-sel ve yalnızca meteorolojik analizlere odaklanan çalışmalar dışlanmıştır. Dışa aktarılan kayıtlar özet içermediğinden eleme başlık ve künye düzeyinde yapılmış, tam metin değerlendirmesi yapılmamıştır. Özet ve tam metin değerlendirmesi bu aşamadan sonra çalışmaya dahil edilen kayıtlar üzerinden yapılmıştır.

Şekil 1. Kaynak seçimi akış şeması



Tablo 1. Tarama ve eleme özeti

Aşama	Web of Science	Scopus	Toplam
Belirlenen kayıt	476	177	653
Yinelenen kayıt (çıkarıldı)	0	4	4
Başlık/künye düzeyinde taranan	476	173	649
Dışlanan (sel dışı anlam: 343; konu/yöntem dışı: 85)	399	29	428
Sentezde değerlendirilen	77	144	221

Küresel Bağlam: Maruziyet, Ölümler ve Yönetim Paradigması

Küresel ölçekte sel-taşkın maruziyeti ve ölümlerine ilişkin dört çalışma bu bölümün küresel çerçevesini oluşturmaktadır. Tellman vd. (2021), 2000–2018 arasındaki 913 büyük sel-taşkın

olayı için günlük uydu görüntülerini kullanarak yaklaşık 2,23 milyon km²'lik sel alanı ve 255–290 milyon doğrudan etkilenen kişi tespit etmiştir. Sel-taşkın gözlenen alanlardaki nüfusun 2000–2015 arasında 58–86 milyon arttığını, bunun sel-taşkına maruz kalan küresel nüfus oranında %20–24'lük bir artışa karşılık geldiğini belirtmiştir. Rentschler vd. (2022), 100 yıllık dönüş süreli bir olayda 0,15 m'nin üzerinde sel-taşkın derinliğine doğrudan maruz kalan nüfusu 1,81 milyar kişi olarak hesaplamıştır. Jonkman vd. (2024), 1975–2022 dönemi için olay başına gerçekleşen ölümlerin azaldığını saptayarak, ani sel ve taşkınların olay başına en yüksek ölüm oranına sahip afetler olduğunu belirtmiştir. Sel ve taşkınlardaki ölüm oranlarının orta ve yüksek gelire sahip ülkelerde düşerken düşük gelirli ülkelerde arttığını ortaya koymuştur. Nearing vd. (2024) ise yapay zekâ tabanlı tahmin sistemlerinin ölçüm istasyonu bulunmayan havzalarda da kullanılma potansiyelini incelemiştir.

Bu çalışmalar, sel-taşkın maruziyetinin geniş bir nüfusu etkilediğini ve risklerin toplumlar arasında eşit dağılmadığını göstermektedir. Bununla birlikte, kaynakların eşit dağılmaması, sel ve taşkınların etkilerinin toplumlar arasında farklılaşmasına neden olmaktadır. Hem maruziyet düzeyini hem de meydana gelen ölüm sayılarını doğrudan etkilemektedir. ABD'de gerçekleştirilen çalışmalar da bu eşitsizliğin farklı boyutlarına dikkat çekmektedir. Wing vd. (2022), sel ve taşkın riskinin mekânsal dağılımındaki eşitsizlikleri incelerken Tate vd. (2021), sosyal kırılganlık ile sel ve taşkınlara maruziyet arasındaki ilişkiyi ele almıştır. Daha geniş bir çerçevede Merz vd. (2021), sel ve taşkın olaylarının nedenlerini, etkilerini ve örüntülerini kapsamlı bir derlemeyle değerlendirmiştir. Kreibich vd. (2022), benzeri görülmemiş sel ve kuraklık olaylarının risk yönetimi açısından ortaya çıkardığı zorlukları ele alırken Brunner vd. (2021), sel ve kuraklıkların modellenmesi ve tahmin edilmesinde karşılaşılan güçlükleri incelemiştir. Öte yandan, sel-

taşkın alanlarındaki yerleşim örüntüleri Devitt vd. (2023) tarafından küresel ölçekte sel-taşkın tehlikesi potansiyeli bağlamında değerlendirilmiştir. Sel yönetimindeki yaklaşım değişimini ele alan Wang vd. (2022), geleneksel sel-taşkın kontrolü anlayışından sel-taşkın dayanıklılığına geçişi derlemiştir. Dottori vd. (2023), Avrupa'da artan nehir taşkını riskine karşı maliyet etkin uyum stratejilerine odaklanırken Liu vd. (2024), 1990–2022 dönemindeki küresel sel-taşkın eğilimlerini ve bu olayların etkilerini incelemiştir.

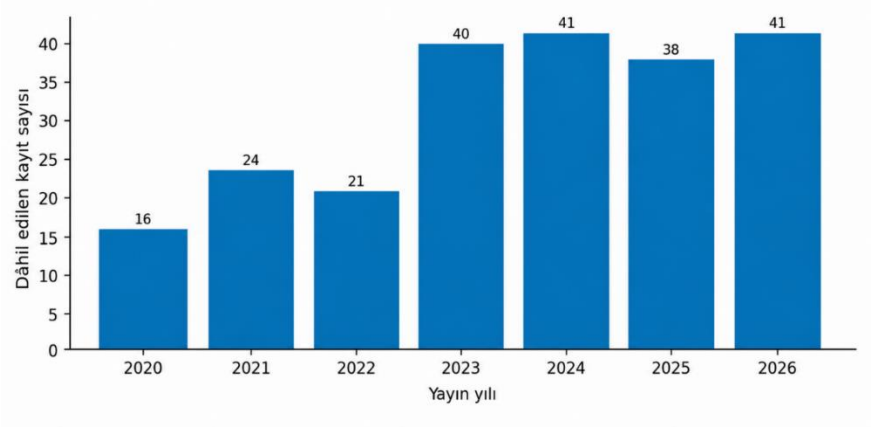
Literatürde Metodolojik Eğilimler (2020–2026)

Bibliyometrik Görünüm

Değerlendirilen 221 kaydın yıllara göre dağılımı, yayın sayısının 2020'de 16'dan 2021'de 24'e yükseldiğini ve sonraki yıllarda genel olarak yüksek seyrettiğini göstermektedir (Grafik 1). 2026 yılına ait sayı, taramanın yapıldığı tarihe bağlı olarak kısmi yılı temsil etmektedir. Bu nedenle yıllar arası karşılaştırmalar yapılırken 2026 verisinin tamamlanmış bir yılı temsil etmediği dikkate alınmalıdır. Çalışmaların en sık yer aldığı dergiler arasında Remote Sensing (26), Water (21), Journal of Hydrology (12), Nature Communications (8) ve Geomatics, Natural Hazards and Risk (8) bulunmaktadır. Bu dağılım, alanın uzaktan algılama, hidroloji ve afet araştırmaları arasında disiplinlerarası bir nitelik taşıdığını göstermektedir.

Başlıklarda geçen kavramlar incelendiğinde haritalama/tespit (69), duyarlılık (68), kentsel/pluvyal (68) ve risk (50) kavramlarının öne çıktığı görülmektedir. Yöntem olarak makine öğrenmesinin 61, topluluk/hibrit/metasezgisel yaklaşımların 34, CBS/coğrafi veri/GeoAI ifadelerinin 30, derin öğrenmenin 19, SAR/Sentinel-1'in 16, AHP/çok kriterli yöntemlerin 13 çalışmada geçtiği görülmektedir.

Grafik 1. Dâhil edilen çalışmaların yıllara göre dağılımı (n = 221; 2026 kısmi yıl)



Yöntem Grupları: İstatistiksel, ÇKKV ve Makine Öğrenmesi

Literatürün üç yöntem grubu etrafında kümelendiği görülmüştür. ÇKKV tabanlı çalışmalarda hibrit ÇKKV ile sel duyarlılığının CBS tabanlı karşılaştırmalı değerlendirmesi (Ali vd., 2020), AHP ile Swarna Nehri Havzası duyarlılık bölgelemesi (Nagamani vd., 2026), Amman'da ani sel riskine kırılganlığın çok kriterli analizi (Al-Rjoub ve Ibrahim, 2026) ve kıyı taşkın riskinin CBS tabanlı mekânsal ÇKKV ile değerlendirilmesi (Hadipour vd., 2020) örnek verilebilir. İkinci grupta AHP ile makine öğrenmesinin karşılaştırıldığı veya birleştirildiği çalışmalar bulunmaktadır. AHP ile gradyan artırmalı ağaç modellerinin karşılaştırılması (Vojtek vd., 2021), veri güdümlü ÇKKV ile makine öğrenmesinin birleştirilmesi (Rashid vd., 2026), CBS ve uzaktan algılamaya dayalı hibrit AHP–MÖ çerçevesi (Wasie vd., 2026) ve TOPSIS ile makine öğrenmesinin birleştirildiği kentsel sel riski değerlendirmesi (Rafiei-Sardooi vd., 2021). Bivariate istatistik ile makine öğrenmesini birleştiren ani sel duyarlılığı modelleri (Liu vd., 2021), istatistiksel, makine öğrenmesi ve topluluk yaklaşımlarının coğrafi tepki

profillerini karşılaştıran çalışmalar (Adnan Ikram vd., 2026) ve ÇKKV ile MÖ'yü destekleyen ani sel duyarlılığı değerlendirmesi (Costache vd., 2020) bu iki aile arasındaki geçişi temsil etmektedir. Metro sistemlerinin sel risk değerlendirmesinde ÇKKV yöntemlerinin derlemesi de ayrıca yapılmış çalışmalardan biridir (Lyu vd., 2023).

Algoritma Kullanımı

Makine öğrenmesi tabanlı çalışmalarda iki eğilimin öne çıktığı görülmüştür. Bunlar; ağaç tabanlı ve topluluk modelleri ile metasezgisel optimizasyonla güçlendirilmiş hibrit modellerdir. Bu çalışmalara rastgele örnekleme stratejisinin RF ve XGBoost ile sel-taşkın duyarlılığına etkisi (Ren vd., 2024), ileri topluluk modelleri (Islam vd., 2021), karıştırma (blending) yaklaşımı (Yin vd., 2023), oylama topluluğu ve metasezgisel özellik seçimi (A. Saleh vd., 2024), artırma (boosting) algoritmalarının karşılaştırmalı mekânsal analizi (Kurugama vd., 2024) ve K-en yakın komşu algoritmasının ince ayarı (Razavi-Termeh vd., 2024) örnek verilebilir. Metasezgisel algoritmalar sel duyarlılığı için ayrıca uygulanmış (Arabameri vd., 2022), karar tablosu sınıflandırıcısı ile metasezgisel yöntemler birleştirilmiş (Askar vd., 2022), ateş böceği–PSO ile optimize edilmiş rastgele alt uzay ağacı kullanılmış (Nhu vd., 2020) ve gri kurt algoritmasıyla sinir ağı hibritlenmiştir (Darabi vd., 2021). Seydi vd. (2023), Cascade Forest dâhil çok sayıda algoritmayı sel duyarlılığı için karşılaştırmıştır. Islam vd. (2021), Teesta Nehri Havzası'nda (Bangladeş) Dagging ve Random Subspace topluluklarını ANN, RF ve SVM ile birleştirerek on iki faktör ve 413 sel noktasıyla modellemiştir.

Derin öğrenme tabanlı çalışmalarda ise farklı ağ mimarilerinin sel-taşkın risk ve duyarlılığını belirleme ve tahmin etme amacıyla kullanıldığı görülmektedir. Fang vd. (2021), bu

kapsamda uzun kısa süreli bellek (LSTM) ağlarıyla sel-taşkın duyarlılığı tahmini yapmıştır. Tsangaratos vd. (2023), bir boyutlu evrişimli sinir ağı (1B CNN) kullanırken Liu vd. (2023), hidrolojik modellemeyi artık sinir ağıyla bütünleştiren bir yaklaşım geliştirmiştir. Plüvyal sel duyarlılığının belirlenmesinde grafik dikkat ağlarından yararlanan Wang vd. (2023), derin öğrenmenin farklı ağ yapılarıyla uygulanmasına örnek oluşturmaktadır. Kalantar vd. (2021), Brisbanede Uzaktan algılama verilerini derin sinir ağıyla birlikte kullanmış, Li vd. (2024) ise Transformer ve LSTM mimarilerini birleştiren hibrit model kullanmıştır.

Uzaktan Algılama ve Derin Öğrenmeyle Sel-Taşkın Haritalama

SAR verileri, bulut örtüsünden büyük ölçüde etkilenmeden görüntü alınabilmesini sağladığı için sel ve taşkınların izlenmesinde önemli bir yere sahiptir. Bu özellik, özellikle optik uydu görüntülerinin yetersiz kaldığı durumlarda SAR tabanlı yöntemlere olan ilgiyi artırmıştır. Amitrano vd. (2024), SAR ile sel tespitinde kullanılan teknikleri ve veri setlerini kapsamlı biçimde ele alırken Liang ve Liu (2020), Sentinel-1 görüntülerinden su yüzeylerinin belirlenmesi için yerel eşikleme yöntemini kullanmıştır. Shastry vd. (2023) ise bulut örtüsü ve bitki örtüsünün sel haritalama üzerindeki etkilerini nicel olarak değerlendirmiştir. Uzaktan algılama temelli sel-taşkın tahminine ilişkin genel bir değerlendirme sunan Munawar vd. (2022) da bu alandaki temel çalışmalardan biridir.

Son yıllarda SAR görüntülerinin işlenmesinde derin öğrenme yöntemlerinden de yararlanılmaktadır. Saleh vd. (2024), SAR tabanlı sel tespitinde diferansiyel dikkat mekanizmasına dayalı Transformer mimarisini kullanırken Jamali vd. (2024), çift polarizasyonlu Sentinel-1 verileriyle artık dalga vizyon U-Net yaklaşımını uygulamıştır. Noori vd. (2025), iki farklı zamana ait SAR görüntülerinin analizinde CNN–Transformer ve U-Net mimarilerini

bir araya getirmiştir. Optik ve SAR görüntülerinin birlikte kullanımına odaklanan Sanderson vd. (2023) ise bu verilerin açıklanabilir derin öğrenme yoluyla birleştirilmesini ele almıştır. Yöntemlerin genel performansına ilişkin önemli bir değerlendirme de Bentivoglio vd. (2022) tarafından yapılmıştır. 58 yayını inceleyen bu derlemede, derin öğrenme yöntemlerinin sel-taşkın haritalamada geleneksel yöntemlere göre daha yüksek doğruluk, sayısal modellere göre ise daha yüksek işlem hızı sağlayabildiği belirtilmiştir. Bununla birlikte, modellerin farklı alanlara uygulanabilirliği ve gerçek zamanlı kullanımı konusunda hâlen çözülmesi gereken sorunlar bulunduğu da vurgulanmıştır.

Kentsel alanlarda bina yoğunluğu ve yüzeylerden kaynaklanan karmaşık radar yansımaları, sel-taşkın haritalamasını daha güç hâle getirmektedir. Bu nedenle kentsel ve kentsel olmayan alanları ayrı ayrı ele alan, farklı veri kaynaklarını birleştiren ve yeni öğrenme yaklaşımlarını deneyen çalışmalar öne çıkmaktadır. Nagato vd. (2026), PALSAR-2 verileri ve coğrafi özelliklerden yararlanarak kentsel ve kentsel olmayan sel-taşkın alanlarını haritalamıştır. Al Mehedi vd. (2026) ise Sentinel-1 verileriyle makine öğrenmesi yöntemlerini kentsel sel-taşkın haritalaması açısından karşılaştırmıştır. Farklı bir yöntemsel yaklaşım benimseyen He vd. (2024), zayıf denetimli semantik segmentasyona dayalı bir kentsel sel-taşkın haritalama çerçevesi geliştirmiştir. Zheng vd. (2026), uzaktan algılama verilerini sosyal medya verileriyle zayıf denetimli bir yaklaşımla birleştirirken Vongkusolkit vd. (2023), yakın gerçek zamanlı sel haritalaması için zayıf denetimli makine öğrenmesinden yararlanmıştır. Plüvyal sel kaynaklı hasarların belirlenmesine yönelik olarak Cerbelaud vd. (2023) tarafından çok sensörlü optik uzaktan algılama verilerini kullanan ve farklı alanlara aktarılabilecek bir yaklaşım da geliştirilmiştir. Son olarak Misra vd. (2025), on yıllık

uydu radar verisini kullanarak küresel ölçekte sel-taşkın haritalaması gerçekleştirmiştir.

Çevresel ve Topografik Parametrelerin Değerlendirilmesi

Sel ve taşkın duyarlılığı modellerinde kullanılan parametreler genel olarak dört grupta ele alınmaktadır. Topografik faktörler yükselti, eğim, bakı, eğrilik, TWI gibi değişkenleri içerirken, hidrolojik faktörler akarsuya uzaklık ve drenaj yoğunluğunu gibi değişkenleri kapsamaktadır. Yüzey özellikleri ve arazi örtüsüne ilişkin değişkenler arasında arazi kullanımı ve örtüsü, NDVI, geçirimsiz yüzeyler ve toprak özellikleri yer alırken iklimsel faktörler çoğunlukla yağış verileri üzerinden değerlendirilmektedir.

Bu değişkenlerin hangilerinin model sonuçları üzerinde daha belirleyici olduğu ve güvenilir bir duyarlılık haritası oluşturmak için kaç parametreye ihtiyaç duyulduğu, literatürde üzerinde durulan konular arasındadır. Al-Kindi ve Alabri (2024), temel koşullandırıcı faktörlerin makine öğrenmesi tabanlı sel duyarlılığı modellerindeki rolünü incelerken Sarkar vd. (2022), daha az sayıda parametre kullanarak güvenilir bir model geliştirme olasılığı üzerinde çalışmıştır. Parametre seçimi ve arazi özelliklerinin temsil edilmesiyle ilgili çalışmalar arasında, yüksek çözünürlüklü jeomorfometrik veri setini ele alan Vojtek vd. (2026), morfometrik analiz ile makine öğrenmesini sel-taşkın riski değerlendirmesinde bir araya getiren Das vd. (2025) ve çok parametreli morfometrik analizden GeoAI ile birlikte yararlanan AlRifai vd. (2025) de bulunmaktadır. Bunun yanı sıra Loots vd. (2025), geçirimsiz yüzey oranının makine öğrenmesi tabanlı sel-taşkın simülasyonlarında kullanılmak üzere nasıl nicelleştirilebileceğini çalışmıştır.

Parametrelerin sel-taşkın duyarlılığı üzerindeki etkisi, çalışmanın yürütüldüğü coğrafi koşullara göre farklılık gösterebilmektedir. Demissie vd. (2024), Kansas'ta 13 değişken ve

1.528 sel-taşkın noktası üzerinden gerçekleştirdikleri analizde akarsuya uzaklık, hidrolojik toprak tipi, yağış, yükselti ve geçirimsiz yüzeyin öne çıkan değişkenler olduğunu belirlemiştir. Pradhan vd. (2023) ise Güney Kore'nin Jinju kentinde, CNN modelinin sonuçlarını SHAP yöntemiyle incelemiş ve arazi kullanımı ile toprak özelliklerinin belirleyici olduğu sonucuna varmıştır. Shenzhen'de yürütülen Wang vd. (2023) çalışması, XGBoost–SHAP yaklaşımıyla kentsel morfolojinin etkisini ortaya koymuştur. Özellikle bina hacminin sel-taşkın duyarlılığına katkısını %9,70 olarak hesaplamıştır. Fu vd. (2025) de benzer bir yaklaşım kullanarak kentsel sel-taşkınlar üzerinde etkili olan temel faktörleri belirlemeye ve bu bulgulardan hareketle hedefe yönelik azaltım stratejileri geliştirmek amacıyla çalışmalarını yürütmüştür. Kuala Lumpur'da Tella vd. (2026) tarafından gerçekleştirilen çalışmada ise birikimli yerel etkiler (ALE) yöntemiyle yıllık yağışın duyarlılığı artırdığı, yükseltinin yaklaşık 50 metrenin altına düştüğü alanlarda duyarlılığın belirgin biçimde yükseldiği ve akarsu kanalından uzaklık yaklaşık 550 metreyi aştığında duyarlılığın hızla azaldığını ortaya koymuştur. Aynı çalışmada düşük NDVI değerlerinin de sel duyarlılığını artırdığı belirlenmiştir. Adnan vd. (2023) ise makine öğrenmesine dayalı jeo-mekânsal sel tahmininde ortaya çıkan belirsizlikleri ele alan bir çerçeve geliştirmiştir. Bu çalışmalar birlikte değerlendirildiğinde, parametrelerin etkisinin her bölgede aynı olmadığı, sonuçların yerel arazi özellikleri, kentsel yapı ve kullanılan modelin açıklanma biçimi dikkate alınarak yorumlanması gerektiği görülmektedir.

Parametrelerin önemi çalışma alanının topoğrafyasına, iklimine, arazi kullanımına, olay envanterinin niteliğine ve kullanılan modelin yapısına bağlı olarak değişebilir. Bu nedenle literatürde sık kullanılan bir değişkenin her havzada aynı ölçüde belirleyici olacağı varsayılmamalıdır. Değişken seçimi ve önem

sıralaması, mümkün olduğunda bağımsız verilerle ve farklı modelleme seçenekleriyle sınanmalıdır.

Makine Öğrenmesi ve YZ Algoritmalarının Performans Karşılaştırması

Sel-taşkın duyarlılık ve risk çalışmalarında modellerin performansı çoğunlukla ROC-AUC değeri üzerinden değerlendirilmektedir. Doğruluk, duyarlılık, kesinlik, F1 skoru ve Kappa katsayısı gibi ölçütler de bu değerlendirmeyi desteklemektedir. Bununla birlikte, model başarısının yalnızca bu ölçütlere bakılarak yorumlanması yeterli olmayabilir. Eğitim ve test verilerinin genellikle rastgele ayrılması, mekânsal otokorelasyonun etkisiyle model performansının gerçekte olduğundan daha yüksek görünmesine yol açabilir. Bu nedenle modellerin farklı mekânsal koşullardaki başarısının da dikkate alınması gerekir. Aşırı öğrenmeyi sınırlandırmak ve elde edilen sonuçların fiziksel süreçlerle daha tutarlı olmasını sağlamak amacıyla Yan vd. (2026) fiziksel kısıtları dikkate alan bir sel duyarlılık haritalama yaklaşımı önermiştir. Waleed ve Sajjad (2025) ise makine öğrenmesi modellerini ölçeklenebilirlik açısından karşılaştırarak model seçiminde performansın yanı sıra uygulanabilirliğin de değerlendirilmesi gerektiğine işaret etmiştir.

Ağaç Tabanlı Modeller

Ağaç tabanlı topluluk yöntemleri, sel-taşkın duyarlılık ve risk çalışmalarında sıkça tercih edilmekte ve birçok uygulamada yüksek ayırt etme başarısı göstermektedir. Al-Aizari vd. (2022), Yemen'de 12 faktör ile 600 sel-taşkın olan ve olmayan noktayı kullanarak KNN, Naif Bayes, Rastgele Orman (RF) ve XGBoost modellerini karşılaştırmıştır. Çalışmada en yüksek başarı, 0,982 AUC değeriyle RF modelinden elde edilmiştir. Tella vd. (2026) ise Kuala Lumpur'da 12 faktör ve 450 sel-taşkın olan ve 450 sel-taşkın

olmayan noktadan oluşan veri setiyle RF, XGBoost ve lojistik regresyon modellerini değerlendirmiştir. RF ve XGBoost için AUC değeri 0,98, doğruluk oranı ise yaklaşık %94 olarak hesaplanırken lojistik regresyonda AUC 0,96 ve doğruluk %90 düzeyinde kalmıştır. Bununla birlikte, McNemar testi RF ile XGBoost arasında istatistiksel açıdan anlamlı bir fark ortaya koymamıştır. Al-Areeq vd. (2022) tarafından Cidde'de yürütülen çalışmada da torbalama topluluğu, lojistik model ağacı, çekirdek SVM ve KNN yöntemleri 141 sel-taşkın noktası üzerinden karşılaştırılmış ve modellerin AUC değerlerinin %89 ile %97 arasında değiştiği belirlenmiştir.

Bu çalışmalar, ağaç tabanlı modellerin sel-taşkın duyarlılık ve risk tahmininde güçlü sonuçlar verebildiğini ortaya koymaktadır. Ancak en başarılı modelin her çalışma alanında aynı olmadığı, sonuçların kullanılan veri setine ve bölgenin özelliklerine göre değişebildiği unutulmamalıdır. Bu modellerin bir başka avantajı da tahmin sonuçlarının yorumlanmasına olanak tanıyan yöntemlerle birlikte kullanılabilmeleridir. Örneğin, Wang vd. (2023) ve Fu vd. (2025) SHAP analizlerinden, Tella vd. (2026) ise ALE yönteminden yararlanarak değişkenlerin model çıktıları üzerindeki etkilerini incelemiştir. Bu analizler, hangi değişkenlerin öne çıktığını ve belirli koşullarda sel-taşkın duyarlılığı ya da risk göstergeleriyle nasıl ilişkilendiğini daha ayrıntılı biçimde değerlendirmeyi mümkün kılmaktadır.

Derin Öğrenme ve Yapay Sinir Ağı Modelleri

Derin öğrenme yöntemleri, özellikle uydu görüntülerinden sel-taşkın alanlarının belirlenmesi, yağış–akış ilişkilerinin zaman içinde tahmin edilmesi ve çok sayıda değişken içeren verilerin analizinde kullanılmaktadır (Kabir vd., 2020; Li vd., 2024; Kao vd., 2020). Sel-taşkın tahminine yönelik çalışmalarda Yao vd. (2026) BiLSTM–U-Net tabanlı bir hibrit model kullanırken, Mohamadiazar

vd. (2024) uydu görüntülerini derin öğrenme yöntemleriyle birlikte değerlendirerek mekânsal ve zamansal analizler yapmıştır. Singh vd. (2021) ise hidrodinamik model sonuçlarından yararlanarak yapay sinir ağı (ANN) tabanlı bir bölgeleme yaklaşımı geliştirmiştir. Jinju'da gerçekleştirilen çalışmada Pradhan vd. (2023), CNN modelinin sonuçlarını SHAP yöntemiyle incelemiş ve AUROC ölçütüne göre %88,4 başarı sonucu elde etmiştir.

Bununla birlikte, derin öğrenme modellerinin başarısı her uygulamada aynı düzeyde değildir. Bentivoglio vd. (2022), bu modellerin farklı bölgelere uyarlanması ve gerçek zamanlı uygulamalarda kullanılması konusundaki güçlükleri olduğunu öne sürmüştür. Bu çalışmada incelenen karşılaştırmalı çalışmalar da tablo biçimindeki sel-taşkın duyarlılık verilerinde derin öğrenme modellerinin ağaç tabanlı yöntemlere her zaman belirgin bir üstünlük sağlamadığını düşündürmektedir. Ancak bu değerlendirme, bütün çalışmalar için geçerli bir sonuç olarak görülmemeli, kullanılan veri seti, model yapısı ve değerlendirme yöntemi dikkate alınarak araştırma bazında ele alınmalıdır.

Hibrit ve Optimize Edilmiş Modeller

Hibrit modeller, tek bir algoritmanın hiperparametre ve girdi sınırlarını aşmak için metasezgisel optimizasyon, çoklu güçlendirme ve fizik bilgisini kullanır. Sel duyarlılığı için ateş böceği–PSO ile rastgele alt uzay ağacı (Nhu vd., 2020), gri kurt algoritması ile sinir ağı (Darabi vd., 2021), karar tablosu sınıflandırıcısı ile metasezgisel yöntemler (Askar vd., 2022), hibrit derin sinir ağı ile istatistiksel öğrenme (Ghobadi ve Ahmadipari, 2024), yeni topluluk yapay zekâ yaklaşımlarıyla mekânsal sel modellemesi (Arabameri vd., 2020) ve rastgele orman ile radyal tabanlı fonksiyon sinir ağının topluluğu (Chen vd., 2020) geliştirilmiştir. Fiziksel süreç bilgisinin entegrasyonu açısından hidrodinamik modelleme, uzaktan algılama

ve topluluk makine öğrenmesini birleştiren sel-taşkın duyarlılığı (Ahmad vd., 2025) ile fizik, derin öğrenme ve veriyi birleştiren hibrit tahmin yaklaşımı (Roohi vd., 2025) öne çıkmaktadır. Aşırı optimize edilmiş modellerde aşırı uyum riski ve optimizasyon maliyeti dikkate alınmalıdır.

Karşılaştırmalı Değerlendirme

Farklı çalışmalarda elde edilen AUC değerlerini doğrudan karşılaştırmak her zaman sağlıklı sonuçlar vermeyebilir. Çünkü çalışmaların yürütüldüğü havzalar, kullanılan parametreler, sel-taşkın olan ve olmayan noktaların seçimi ile doğrulama yöntemleri birbirinden farklıdır. Özellikle negatif örneklerin nasıl belirlendiği ve iki grup arasındaki oranın ne olduğu, modelin başarı düzeyini önemli ölçüde etkileyebilir. Bazı çalışmalarda elde edilen çok yüksek AUC değerleri de tek başına modelin güçlü bir genelleme yeteneğine sahip olduğunu göstermeyebilir. Veri sızıntısı, mekânsal otokorelasyon veya sel olmayan noktaların kolay ayırt edilebilecek alanlardan seçilmesi bu sonuçları etkilemiş olabilir.

Yöntemler arasındaki farklılıklar da karşılaştırma yapılırken göz önünde bulundurulmalıdır. ÇKKV yaklaşımlarında sonuçlar çoğunlukla geçmiş sel-taşkın kayıtları ve elde edilen haritaların mekânsal açıdan tutarlılığı üzerinden değerlendirilirken, makine öğrenmesi çalışmalarında AUC gibi istatistiksel ölçütler daha sık kullanılmaktadır. Dolayısıyla bu iki yaklaşımın başarısını yalnızca tek bir ölçüt üzerinden karşılaştırmak uygun değildir. Çalışmaların kendi koşulları içinde değerlendirilmesi, mümkün olduğunda bağımsız verilerle doğrulanması ve farklı doğrulama sonuçlarının birlikte ele alınması, yöntemlerin gerçek başarısı hakkında daha güvenilir bir değerlendirme yapılmasını sağlayacaktır.

Mevcut Kısıtlılıklar ve Gelecekteki Araştırma Yönelimleri

Kısıtlılıklar

Sel-taşkın duyarlılığı ve risk değerlendirmelerinde farklı yöntemler kullanılsa da çalışmaların önemli bir bölümü benzer sorunlarla karşılaşmaktadır. Bunların başında veri kalitesi, modellerin gelecekteki değişimleri yansıtma kapasitesi ve elde edilen sonuçların farklı alanlarda ne ölçüde geçerli olduğu gelmektedir.

Yüksek çözünürlüklü sayısal yükseklik modellerine ve kentsel mikro-topografyayı gösteren ayrıntılı verilere erişim her zaman mümkün değildir. Bu verilerin temini maliyetli olabildiği gibi, açık erişimli küresel DEM ürünlerinin sel-taşkın eğilimli alanlardaki doğruluğu da değişkenlik göstermektedir (Meadows vd., 2024). Mevcut duyarlılık haritalarının çoğu geçmiş sel kayıtlarından ve belirli bir döneme ait çevresel verilerden yararlanılarak hazırlanmaktadır. Bu nedenle iklim koşullarında ve arazi kullanımında zamanla meydana gelebilecek değişimler haritalara yeterince yansıtılamayabilir. Gelecekteki koşulları dikkate alan duyarlılık analizlerine yönelik çalışmaların ise sınırlı olduğu görülmektedir (Khodaei vd., 2025; Amiri vd., 2024; Yang vd., 2026).

Veri güdümlü modeller, eğitim verilerindeki ilişkileri başarılı biçimde öğrenebilse de her zaman gerçek hidrolojik süreçlerle uyumlu sonuçlar üretmeyebilir. Ayrıca modelin eğitim verilerine aşırı uyum sağlaması, yeni veriler üzerindeki başarısını düşürebilir (Yan vd., 2026). Modellerin başarısı çoğu zaman aynı çalışma alanından alınan eğitim ve test verileri üzerinden değerlendirilmektedir. Mekânsal çapraz doğrulamanın ve farklı bir bölgede bağımsız sınamanın yaygın olmaması, sonuçların başka alanlara ne ölçüde aktarılabileceğini değerlendirmeyi güçleştirmektedir. Derin öğrenme modellerinin genelleme kapasitesi

de bu açıdan önemli bir sorun olarak öne çıkmaktadır (Bentivoglio vd., 2022).

Kullanılan verilerden, seçilen parametrelerden ve model tercihlerinden kaynaklanan belirsizlikler her çalışmada ayrıntılı biçimde ele alınmamaktadır. Bu belirsizliklerin nicel olarak ortaya konulmaması, üretilen haritaların ne ölçüde güvenilir olduğunun değerlendirilmesini zorlaştırmaktadır (Adnan vd., 2023). ÇKKV yöntemlerinde parametrelere verilen ağırlıklar çoğunlukla uzman görüşlerine dayanmaktadır. Bu durum, uzman görüşlerindeki farklılıkların sonuçlara yansımasına ve aynı çalışma alanı için farklı duyarlılık haritalarının üretilmesine neden olabilir (Nagamani vd., 2026; Al-Rjoub ve Ibrahim, 2026). Akademik çalışmalarda üretilen haritaların ve model sonuçlarının yerel yönetimlerin planlama süreçlerine aktarılması her zaman yeterli düzeyde gerçekleşmemektedir. Bu nedenle bilimsel bulguların uygulamaya dönüştürülmesi ve karar alma süreçlerinde etkin biçimde kullanılması önemli bir sorun olmaya devam etmektedir (Truu vd., 2021).

Gelecek Yönelimleri

Sel-taşkın çalışmalarında öne çıkan yönelimlerden biri, sensörlerden ve Nesnelerin İnterneti (IoT) sistemlerinden elde edilen verilerin yapay zekâ ile birlikte değerlendirilerek erken uyarı süreçlerinde kullanılmasıdır. Dubai'de kentsel sel esnekliğini artırmaya yönelik YZ destekli IoT sistemleri (Gbran, 2026), akıllı hidro-enformatik yaklaşımlara dayanan kentsel sel erken uyarı sistemi (Dang vd., 2025) ve yüksek çözünürlüklü, etki temelli nehir taşkını erken uyarı sistemi (Najafi vd., 2024) bu alandaki örnekler arasındadır. Nearing vd. (2024), yapay zekâ tabanlı tahminlerin ölçüm istasyonu bulunmayan havzalarda da güvenilir sonuçlar üretebildiğini göstermiştir. Bunun yanı sıra, uzaktan algılama

verilerini sayısal ikiz teknolojisiyle birleştiren kentsel sel yönetimi uygulamaları (Hlal vd., 2025) ve sel bilgisiyle kısıtlanmış, CBS ile etkileşimli büyük dil modelleri (Zhu vd., 2024) yeni araştırma alanları olarak dikkat çekmektedir.

Uydu gözlemlerinin yapay zekâ yöntemleriyle birlikte kullanılması, sel-taşkın alanlarının belirlenmesi ve olayların farklı zamanlarda izlenmesi açısından önemini korumaktadır. Sentinel-1 SAR verilerinin optik uydu görüntüleri ve yüksek çözünürlüklü verilerle birleştirildiği çok sensörlü haritalama çalışmaları (Liu vd., 2026; Shampa vd., 2025), on yıllık uydu radar verilerinden yararlanılarak gerçekleştirilen küresel sel haritalaması (Misra vd., 2025) bu yöndeki uygulamalara örnek verilebilir. Ayrıca, yapay zekâ ile çok sensörlü Yer Gözlemi verilerinin sel tahmini ve haritalamasında kullanımını ele alan sistematik derlemeler de alanın gelişimini ortaya koymaktadır (Kemarau vd., 2026; Sibandze vd., 2026).

Gelecekteki sel-taşkın riski ve duyarlılığını değerlendirebilmek için iklim değişikliğinin yanı sıra arazi kullanımındaki değişimlerin de analizlere dâhil edilmesi gerekmektedir. Khodaei vd. (2025), iklim ve arazi kullanımı değişimleri altında gelecekteki sel-taşkın duyarlılığının haritalanmasını konu edinirken Amiri vd. (2024), uzaktan algılama verilerini de içeren yeni bir makine öğrenmesi aracıyla güncel ve gelecekteki duyarlılık değerlendirmelerini ele almıştır. Yang vd. (2026) iklim değişikliği koşullarında çok değişkenli sel-taşkın riski değerlendirmesi yapmış, Simonovic ve Perry (2025) ise Kanada için güncel ve geleceğe yönelik toplam sel-taşkın tehlikesi haritalamasına ilişkin literatürü incelemiştir. Bu çalışmalar, yalnızca mevcut koşulları gösteren haritaların ötesine geçilmesi ve olası gelecek senaryolarının da değerlendirilmesi gerektiğine işaret etmektedir.

Makine öğrenmesi modellerinin fiziksel süreçleri temsil eden modellerle birlikte kullanılması, tahminlerin hidrolojik açıdan tutarlılığını artırmaya yönelik yaklaşımlardan biridir (Ahmad vd., 2025; Roohi vd., 2025). Bunun yanında SHAP ve ALE gibi açıklanabilir yapay zekâ yöntemleri, model sonuçlarının hangi değişkenlerle ve hangi koşullarda ilişkili olduğunu anlamayı kolaylaştırmaktadır (Pradhan vd., 2023; Tella vd., 2026). Bu yöntemlerin sonuçlarla birlikte düzenli biçimde raporlanması, modellerin yalnızca tahmin başarısının değil, ürettikleri sonuçların nasıl yorumlanabileceğinin de değerlendirilmesine katkı sağlayabilir.

Sel-taşkın değerlendirmelerinde yalnızca fiziksel tehlikenin veya maruziyetin belirlenmesi yeterli değildir. Toplumsal kırılganlıkların da dikkate alınması gerekir. Bu yaklaşım, sel olaylarından daha fazla etkilenebilecek grupların belirlenmesine ve uyum planlamasında önceliklerin buna göre oluşturulmasına yardımcı olabilir. ABD'de sel riskinin eşitsiz dağılımını inceleyen çalışmalar (Wing vd., 2022), sosyal kırılganlık ile sel maruziyeti arasındaki ilişkiyi ele alan araştırmalar (Tate vd., 2021), Afrika'da yetersiz konutların sel-taşkın riskine maruziyeti (Liang ve Zhang, 2026) ve Tayland'da topluluk esnekliğine odaklanan çalışma (Littidej vd., 2026) bu konunun farklı boyutlarını ortaya koymaktadır. Bu çalışmalar, sel-taşkın analizlerinin toplumsal koşulları da kapsayacak biçimde geliştirilmesinin önemini ortaya koymaktadır.

Sonuç ve Öneriler

Bu inceleme, CBS ile YZ yöntemlerinin sel-taşkın çalışmalarındaki kullanımının, yalnızca yeni algoritmaların geliştirilmesiyle sınırlı olmadığını, veri üretimi, mekânsal analiz, model doğrulama ve karar destek süreçlerini de kapsayan daha geniş

bir dönüşümün parçası olduğunu göstermektedir. Web of Science ve Scopus kayıtları üzerinden incelenen literatürde yayın sayısının 2020'den 2023–2026 dönemine kadar iki katından fazla artması, bu alana yönelik bilimsel ilginin güçlendiğine işaret etmektedir. Çalışmaların haritalama ve olay tespiti, duyarlılık analizi ve kentsel sel konularında yoğunlaşması ise araştırma gündeminin hem sel-taşkın olaylarının mekânsal dağılışını belirlemeye hem de kentlerdeki etkilerini daha iyi anlamaya yöneldiğini ortaya koymaktadır.

Literatürdeki yöntemsel gelişmeler üç temel eğilim üzerinden değerlendirilebilir. İlk olarak, Rastgele Orman ve XGBoost gibi ağaç tabanlı topluluk modelleri, çok sayıda çevresel değişkeni birlikte değerlendirebilmeleri ve birçok uygulamada yüksek ayırt etme başarısı göstermeleri nedeniyle öne çıkmaktadır. İkinci olarak, derin öğrenme ve özellikle uydu görüntüleriyle birlikte kullanılan SAR tabanlı yaklaşımlar, sel alanlarının belirlenmesi ve olayların mekânsal olarak izlenmesi için yeni olanaklar sunmaktadır. Üçüncü olarak, SHAP ve ALE gibi açıklanabilir yapay zekâ yöntemleri, modellerin hangi değişkenlere dayanarak sonuç ürettiğinin anlaşılmasını kolaylaştırmaktadır. Bununla birlikte, bu gelişmeler tek başına daha güvenilir sonuçlar elde edildiği anlamına gelmemektedir. Model başarısı, kullanılan verilerin niteliğine, örnekleme stratejisine, doğrulama yöntemine ve çalışma alanının özelliklerine bağlıdır. Dolayısıyla literatürde bildirilen yüksek başarı değerleri, farklı çalışmalar arasında doğrudan bir üstünlük sıralaması yapmak için yeterli değildir.

Bu çalışmada ulaştığımız bir diğer sonuç ise yöntem seçiminin algoritmaların başarısından bağımsız düşünülemeyeceğidir. Güvenilir sel-taşkın envanterinin bulunmadığı veya veri altyapısının yetersiz olduğu alanlarda, uzman görüşüne dayanan ÇKKV ve istatistiksel yöntemler uygulanabilir bir

başlangıç sunmaktadır. Yeterli sayıda ve niteliği bilinen olay kaydının bulunduğu alanlarda ise makine öğrenmesi modelleri, değişkenler arasındaki ilişkileri ortaya koyma ve mekânsal ayrım gücünü artırma bakımından avantaj sağlayabilir. Fiziksel süreçleri temsil eden modellerle veri güdümlü yöntemlerin birleştirilmesi de iki yaklaşımın güçlü yönlerinden yararlanma potansiyeli taşımaktadır. Ancak bu seçeneklerin hiçbiri bütün çalışma alanları için geçerli tek bir çözüm olarak görülmemelidir; yöntem tercihi, araştırma sorusu ve mevcut veri koşullarıyla birlikte ele alınmalıdır.

Gelecek araştırmalar açısından gerçek zamanlı sensör verileriyle erken uyarı sistemlerinin bütünleştirilmesi, uydu gözlemlerinin derin öğrenme yöntemleriyle birlikte kullanılması ve iklim ile arazi kullanımı senaryolarının analizlere dâhil edilmesi öne çıkan yönelimlerdir. Bunun yanında, sosyal kırılganlık ve eşitsiz maruziyet göstergelerinin değerlendirmelere katılması, sel-taşkın çalışmalarının yalnızca fiziksel çevreyi değil, olaylardan etkilenebilecek toplulukları da kapsamasını sağlayacaktır. Bu gelişmelerin uygulamaya aktarılabilmesi ise güncel ve güvenilir veri altyapısına, açık yöntemsel raporlamaya ve bilimsel çıktılarla planlama süreçleri arasında kurulacak iş birliğine bağlıdır.

Sonuç olarak, CBS ile YZ'nin bütünleştirilmesi sel-taşkın olaylarının mekânsal analizinde önemli olanaklar sunmaktadır. Ancak bu olanakların gerçek bir karar desteğine dönüşmesi, kullanılan algoritmanın gelişmişliğinden çok daha fazlasını gerektirir. Güvenilir veri, uygun yöntem seçimi, bağımsız doğrulama, belirsizliğin dikkate alınması ve duyarlılık ile risk arasındaki ayrımın korunması bu sürecin temel koşullarıdır. Alanın gelecekteki gelişimi, yalnızca daha başarılı tahminler üreten modeller geliştirmekle değil, bu modellerin sonuçlarını fiziksel ve toplumsal bağlam içinde açıklayabilmek ve planlama kararlarında güvenilir biçimde kullanabilmekle ölçülmelidir.

Kaynakça

Aboulola, O. I., Bahouq, T., Elmotawakkil, A., & Moumane, A. (2026). Geospatial Artificial Intelligence (GeoAI) Framework for Flood Susceptibility Mapping Using a Hybrid SVM–XGBoost Model. IEEE Access, 14, 145703. https://doi.org/10.1109/access.2026.3735873

Adnan Ikram, R. M., Han, J. C., Wang, M., Moayedi, H., & Moradi, M. (2026). Geographical reaction profiles of flood occurrence: insights from statistical, machine-learning, and ensemble models. Geomatics, Natural Hazards and Risk, 17(1), 2698976. https://doi.org/10.1080/19475705.2026.2698976

Adnan, M. S. G., Siam, Z. S., Kabir, I., Kabir, Z., Ahmed, M. R., Hassan, Q. K., vd. (2023). A novel framework for addressing uncertainties in machine learning-based geospatial approaches for flood prediction. Journal of Environmental Management, 326, 116813. https://doi.org/10.1016/j.jenvman.2022.116813

Ahmad, I., Farooq, R., Ashraf, M., Waseem, M., & Shangguan, D. (2025). Improving flood hazard susceptibility assessment by integrating hydrodynamic modeling with remote sensing and ensemble machine learning. Natural Hazards, 121(7), 7839. https://doi.org/10.1007/s11069-025-07109-2

Al-Aizari, A. R., Al-Masnay, Y. A., Aydda, A., Zhang, J., Ullah, K., Islam, A. R. M. T., vd. (2022). Assessment Analysis of Flood Susceptibility in Tropical Desert Area: A Case Study of Yemen. Remote Sensing, 14(16), 4050. https://doi.org/10.3390/rs14164050

Al-Areeq, A. M., Abba, S. I., Yassin, M. A., Benaaf, M., Ghaleb, M., & Aljundi, I. H. (2022). Computational Machine Learning Approach for Flood Susceptibility Assessment Integrated with Remote Sensing

and GIS Techniques from Jeddah, Saudi Arabia. Remote Sensing, 14(21), 5515. https://doi.org/10.3390/rs14215515

Ali, S. A., Parvin, F., Pham, Q. B., Vojtek, M., Vojteková, J., Costache, R., vd. (2020). GIS-based comparative assessment of flood susceptibility mapping using hybrid multi-criteria decision-making approach, naïve Bayes tree, bivariate statistics and logistic regression: A case of Topľa basin, Slovakia. Ecological Indicators, 117, 106620. https://doi.org/10.1016/j.ecolind.2020.106620

Al-Kindi, K. M., & Alabri, Z. (2024). Investigating the Role of the Key Conditioning Factors in Flood Susceptibility Mapping Through Machine Learning Approaches. Earth Systems and Environment, 8(1), 63. https://doi.org/10.1007/s41748-023-00369-7

Al Mehedi, M. A., Smith, V., & Kremer, P. (2026). Comparative Analysis of Urban Flood Mapping Using Sentinel-1 SAR Imagery and Machine Learning. Journal of Flood Risk Management, 19(3), e70246. https://doi.org/10.1111/jfr3.70246

AlRifai, M. H., Kafy, A. A., & Altuwaijri, H. A. (2025). Quantitative Assessment of Flood Risk Through Multi Parameter Morphometric Analysis and GeoAI: A GIS-Based Study of Wadi Ranuna Basin in Saudi Arabia. Water (Switzerland), 17(14), 2108. https://doi.org/10.3390/w17142108

Al-Rjoub, E., & Ibrahim, M. (2026). Multi-criteria analysis to assess the area's vulnerability to instantaneous flood risk using GIS in Amman city, Jordan. Water Science and Technology, 93(2), 113. https://doi.org/10.2166/wst.2025.189

Amiri, A., Soltani, K., Ebtehaj, I., & Bonakdari, H. (2024). A novel machine learning tool for current and future flood susceptibility mapping by integrating remote sensing and geographic information

systems. Journal of Hydrology, 632, 130936. https://doi.org/10.1016/j.jhydrol.2024.130936

Amitrano, D., Di Martino, G., Di Simone, A., & Imperatore, P. (2024). Flood Detection with SAR: A Review of Techniques and Datasets. Remote Sensing, 16(4), 656. https://doi.org/10.3390/rs16040656

Anik, M. S. B. M., An, C., & Li, S. S. (2025). Evolution from the physical process-based approaches to machine learning approaches to predicting urban floods: a literature review. Environmental Systems Research, 14(1), 15. https://doi.org/10.1186/s40068-025-00409-3

Arabameri, A., Saha, S., Mukherjee, K., Blaschke, T., Chen, W., Ngo, P. T. T., vd. (2020). Modeling spatial flood using novel ensemble artificial intelligence approaches in northern Iran. Remote Sensing, 12(20), 3423. https://doi.org/10.3390/rs12203423

Arabameri, A., Seyed Danesh, A., Santosh, M., Cerda, A., Chandra Pal, S., Ghorbanzadeh, O., vd. (2022). Flood susceptibility mapping using meta-heuristic algorithms. Geomatics, Natural Hazards and Risk, 13(1), 949. https://doi.org/10.1080/19475705.2022.2060138

A. Saleh, R., Al-Areeq, A. M., Al Aghbari, A. A., Ghaleb, M., Benaafi, M., Al-Areeq, N. M., vd. (2024). A novel voting ensemble model empowered by metaheuristic feature selection for accurate flash flood susceptibility mapping. Geomatics, Natural Hazards and Risk, 15(1), 2360000. https://doi.org/10.1080/19475705.2024.2360000

Askar, S., Zeraat Peyma, S., Yousef, M. M., Prodanova, N. A., Muda, I., Elsahabi, M., vd. (2022). Flood Susceptibility Mapping Using Remote Sensing and Integration of Decision Table Classifier and

Metaheuristic Algorithms. Water (Switzerland), 14(19), 3062. https://doi.org/10.3390/w14193062

Bentivoglio, R., Isufi, E., Jonkman, S. N., & Taormina, R. (2022). Deep learning methods for flood mapping: a review of existing applications and future research directions. Hydrology and Earth System Sciences, 26(16), 4345. https://doi.org/10.5194/hess-26-4345-2022

Bi, W., Schooling, J., & Macaskill, K. (2024). Assessing flood resilience of urban rail transit systems: Complex network modelling and stress testing in a case study of London. Transportation Research Part D-Transport and Environment, 134, 104263. https://doi.org/10.1016/j.trd.2024.104263

Brunner, M. I., Slater, L., Tallaksen, L. M., & Clark, M. (2021). Challenges in modeling and predicting floods and droughts: A review. Wiley Interdisciplinary Reviews-Water, 8(3), e1520. https://doi.org/10.1002/wat2.1520

Cerbelaud, A., Blanchet, G., Roupioz, L., Breil, P., & Briottet, X. (2023). Mapping Pluvial Flood-Induced Damages with Multi-Sensor Optical Remote Sensing: A Transferable Approach. Remote Sensing, 15(9), 2361. https://doi.org/10.3390/rs15092361

Chen, J., Li, Q., Wang, H., & Deng, M. (2020). A machine learning ensemble approach based on random forest and radial basis function neural network for risk evaluation of regional flood disaster: A case study of the yangtze river delta, China. International Journal of Environmental Research and Public Health, 17(1), 49. https://doi.org/10.3390/ijerph17010049

Costache, R., Pham, Q. B., Sharifi, E., Linh, N. T. T., Abba, S. I., Vojtek, M., vd. (2020). Flash-flood susceptibility assessment using

multi-criteria decision making and machine learning supported by remote sensing and GIS techniques. Remote Sensing, 12(1), 106. https://doi.org/10.3390/rs12010106

Dang, T. Q., Tran, B. H., Le, Q. N., Tanim, A. H., Bui, V. H., Mai, S. T., vd. (2025). Integrating Intelligent Hydro-informatics into an effective Early Warning System for risk-informed urban flood management. Environmental Modelling and Software, 183, 106246. https://doi.org/10.1016/j.envsoft.2024.106246

Darabi, H., Torabi Haghighi, A., Rahmati, O., Jalali Shahrood, A., Rouzbeh, S., Pradhan, B., vd. (2021). A hybridized model based on neural network and swarm intelligence-grey wolf algorithm for spatial prediction of urban flood-inundation. Journal of Hydrology, 603, 126854. https://doi.org/10.1016/j.jhydrol.2021.126854

Das, P., Sarkar, D., Saha, S., Saikh, N. I., & Mondal, P. (2025). Integrated morphometric and machine learning-based flood risk assessment in the Rangit river sub-watersheds, Eastern Himalayas. Discover Applied Sciences, 7(10), 1156. https://doi.org/10.1007/s42452-025-07776-7

Demissie, Z., Rimal, P., Seyoum, W. M., Dutta, A., & Rimmington, G. (2024). Flood susceptibility mapping: Integrating machine learning and GIS for enhanced risk assessment. Applied Computing and Geosciences, 23, 100183. https://doi.org/10.1016/j.acags.2024.100183

Derman, M. T., & Mete, M. O. (2025). Flood Risk Analysis with Explainable Geospatial Artificial Intelligence (GeoAI) Techniques. Systems, 13(11), 1007. https://doi.org/10.3390/systems13111007

Devitt, L., Neal, J., Coxon, G., Savage, J., & Wagener, T. (2023). Flood hazard potential reveals global floodplain settlement patterns.

Nature Communications, 14(1), 2801. https://doi.org/10.1038/s41467-023-38297-9

Dong, S., Gao, X., Mostafavi, A., Gao, J., & Gangwal, U. (2023). Characterizing resilience of flood-disrupted dynamic transportation network through the lens of link reliability and stability. Reliability Engineering & System Safety, 232, 109071. https://doi.org/10.1016/j.ress.2022.109071

Dottori, F., Mentaschi, L., Bianchi, A., Alfieri, L., & Feyen, L. (2023). Cost-effective adaptation strategies to rising river flood risk in Europe. Nature Climate Change. https://doi.org/10.1038/s41558-022-01540-0

Fang, Z., Wang, Y., Peng, L., & Hong, H. (2021). Predicting flood susceptibility using LSTM neural networks. Journal of Hydrology, 594, 125734. https://doi.org/10.1016/j.jhydrol.2020.125734

Fu, X., Wang, M., Zhang, D., Chen, F., Peng, X., Wang, L., vd. (2025). An XGBoost-SHAP framework for identifying key drivers of urban flooding and developing targeted mitigation strategies. Ecological Indicators, 175, 113579. https://doi.org/10.1016/j.ecolind.2025.113579

Gbran, H. (2026). AI-enabled IoT systems for urban flood resilience: a validated case study from Dubai. Proceedings of the Institution of Civil Engineers: Smart Infrastructure and Construction, 179(1-2), 33. https://doi.org/10.1680/jsmic.25.00038

Ghobadi, M., & Ahmadipari, M. (2024). Enhancing Flood Susceptibility Modeling: a Hybrid Deep Neural Network with Statistical Learning Algorithms for Predicting Flood Prone Areas. Water Resources Management, 38(8), 2687. https://doi.org/10.1007/s11269-024-03770-7

Guo, K., Guan, M., & Yu, D. (2021). Urban surface water flood modelling - a comprehensive review of current models and future challenges. Hydrology and Earth System Sciences, 25(5), 2843. https://doi.org/10.5194/hess-25-2843-2021

Hadipour, V., Vafaie, F., & Deilami, K. (2020). Coastal flooding risk assessment using a GIS-based spatial multi-criteria decision analysis approach. Water (Switzerland), 12(9), 2379. https://doi.org/10.3390/w12092379

He, Y., Wang, J., Zhang, Y., & Liao, C. (2024). An efficient urban flood mapping framework towards disaster response driven by weakly supervised semantic segmentation with decoupled training samples. ISPRS Journal of Photogrammetry and Remote Sensing, 207, 338. https://doi.org/10.1016/j.isprsjprs.2023.12.009

Hlal, M., Baraka Munyaka, J. C., Chenal, J., Azmi, R., Diop, E. B., Bounabi, M., vd. (2025). Digital Twin Technology for Urban Flood Risk Management: A Systematic Review of Remote Sensing Applications and Early Warning Systems. Remote Sensing, 17(17), 3104. https://doi.org/10.3390/rs17173104

Islam, A. R. M. T., Talukdar, S., Mahato, S., Kundu, S., Eibek, K. U., Pham, Q. B., vd. (2021). Flood susceptibility modelling using advanced ensemble machine learning models. Geoscience Frontiers, 12(3), 101075. https://doi.org/10.1016/j.gsf.2020.09.006

Islam, T., Zeleke, E. B., Afroz, M., & Melesse, A. M. (2025). A Systematic Review of Urban Flood Susceptibility Mapping: Remote Sensing, Machine Learning, and Other Modeling Approaches. Remote Sensing, 17(3), 524. https://doi.org/10.3390/rs17030524

Jamali, A., Roy, S. K., Beni, L. H., Pradhan, B., Li, J., & Ghamisi, P. (2024). Residual wave vision U-Net for flood mapping using dual

polarization Sentinel-1 SAR imagery. International Journal of Applied Earth Observation and Geoinformation, 127, 103662. https://doi.org/10.1016/j.jag.2024.103662

Jonkman, S. N., Curran, A., & Bouwer, L. M. (2024). Floods have become less deadly: an analysis of global flood fatalities 1975-2022. Natural Hazards, 120(7), 6327. https://doi.org/10.1007/s11069-024-06444-0

Kabir, S., Patidar, S., Xia, X., Liang, Q., Neal, J., & Pender, G. (2020). A deep convolutional neural network model for rapid prediction of fluvial flood inundation. Journal of Hydrology, 590, 125481. https://doi.org/10.1016/j.jhydrol.2020.125481

Kalantar, B., Ueda, N., Saeidi, V., Janizadeh, S., Shabani, F., Ahmadi, K., vd. (2021). Deep neural network utilizing remote sensing datasets for flood hazard susceptibility mapping in Brisbane, Australia. Remote Sensing, 13(13), 2638. https://doi.org/10.3390/rs13132638

Kao, I. F., Zhou, Y., Chang, L. C., & Chang, F. J. (2020). Exploring a Long Short-Term Memory based Encoder-Decoder framework for multi-step-ahead flood forecasting. Journal of Hydrology, 583, 124631. https://doi.org/10.1016/j.jhydrol.2020.124631

Kemarau, R. A., Muhamad, N., Shamsuddin, A. S., Sa'adi, Z., Sakawi, Z., Eboy, O. V., vd. (2026). Artificial intelligence and multi-sensor earth observation for flood forecasting and mapping: a systematic review of operational evidence. Egyptian Journal of Remote Sensing and Space Science, 29(4), 683. https://doi.org/10.1016/j.ejrs.2026.09.002

Khodaei, H., Saleh, F. N., Dalir, A. N., & Zarei, E. (2025). Future flood susceptibility mapping under climate and land use change.

Scientific Reports, 15(1), 12394. https://doi.org/10.1038/s41598-025-97008-0

Kreibich, H., Van Loon, A. F., Schröter, K., Ward, P. J., Mazzoleni, M., Sairam, N., vd. (2022). The challenge of unprecedented floods and droughts in risk management. Nature, 608(7921), 80. https://doi.org/10.1038/s41586-022-04917-5

Krishnachaithanya, N., Bagavathi Sivakumar, P., & Deepika, T. (2025). Probabilistic flood risk mapping for Indian megacities using a scalable machine learning framework in Google Earth engine. Results in Engineering, 28, 107872. https://doi.org/10.1016/j.rineng.2025.107872

Kurugama, K. M., Kazama, S., Hiraga, Y., & Samarasuriya, C. (2024). A comparative spatial analysis of flood susceptibility mapping using boosting machine learning algorithms in Rathnapura, Sri Lanka. Journal of Flood Risk Management, 17(2), e12980. https://doi.org/10.1111/jfr3.12980

Liang, J., & Liu, D. (2020). A local thresholding approach to flood water delineation using Sentinel-1 SAR imagery. ISPRS Journal of Photogrammetry and Remote Sensing, 159, 53. https://doi.org/10.1016/j.isprsjprs.2019.10.017

Liang, L., & Zhang, L. (2026). Mapping inadequate housing exposure to flood risk in Africa from 2005 to 2020. Big Earth Data. https://doi.org/10.1080/20964471.2026.2694887

Littidej, P., Pumhirunroj, B., & Slack, D. (2026). Flood Risk and Community Resilience in Northeast Thailand: A Multi-Temporal Analysis of Population Dynamics and Environmental Indicators for Sustainable Development. Sustainability (Switzerland), 18(17), 8912. https://doi.org/10.3390/su18178912

Liu, J., Liu, K., & Wang, M. (2023). A Residual Neural Network Integrated with a Hydrological Model for Global Flood Susceptibility Mapping Based on Remote Sensing Datasets. Remote Sensing, 15(9), 2447. https://doi.org/10.3390/rs15092447

Liu, J., Wang, J., Xiong, J., Cheng, W., Sun, H., Yong, Z., vd. (2021). Hybrid models incorporating bivariate statistics and machine learning methods for flash flood susceptibility assessment based on remote sensing datasets. Remote Sensing, 13(23), 4945. https://doi.org/10.3390/rs13234945

Liu, Q., Du, M., Wang, Y., Deng, J., Yan, W., Qin, C., vd. (2024). Global, regional and national trends and impacts of natural floods, 1990-2022. Bulletin of the World Health Organization, 102(6), 410. https://doi.org/10.2471/blt.23.290243

Liu, Y., Wang, X., Kong, X., Ye, Y., Xu, X., Zhao, B., vd. (2026). Machine learning–based flood inundation mapping using fused optical and SAR remote sensing: a case study of the Miyun flood. Frontiers in Earth Science, 14, 1805240. https://doi.org/10.3389/feart.2026.1805240

Li, W., Liu, C., Xu, Y., Niu, C., Li, R., Li, M., vd. (2024). An interpretable hybrid deep learning model for flood forecasting based on Transformer and LSTM. Journal of Hydrology-Regional Studies, 54, 101873. https://doi.org/10.1016/j.ejrh.2024.101873

Loots, I., Smithers, J. C., & Kjeldsen, T. R. (2025). Quantifying urban land cover imperviousness as input for flood simulation using machine learning: South African case study. Water Science and Technology, 91(10), 1141. https://doi.org/10.2166/wst.2025.067

Lyu, H. M., Yin, Z. Y., Zhou, A., & Shen, S. L. (2023). MCDM-based flood risk assessment of metro systems in smart city

development: A review. Environmental Impact Assessment Review, 101, 107154. https://doi.org/10.1016/j.eiar.2023.107154

Lyu, H., Yin, Z., Shen, S., Chen, X., & Su, D. (2025). A novel framework incorporating machine learning into GIS for flood susceptibility prediction of urban metro systems. Science China Technological Sciences, 68(6), 1620701. https://doi.org/10.1007/s11431-024-2925-8

Meadows, M., Jones, S., & Reinke, K. (2024). Vertical accuracy assessment of freely available global DEMs (FABDEM, Copernicus DEM, NASADEM, AW3D30 and SRTM) in flood-prone environments. International Journal of Digital Earth, 17(1), 2308734. https://doi.org/10.1080/17538947.2024.2308734

Merz, B., Blöschl, G., Vorogushyn, S., Dottori, F., Aerts, J. C. J. H., Bates, P., vd. (2021). Causes, impacts and patterns of disastrous river floods. Nature Reviews Earth & Environment, 2(9), 592. https://doi.org/10.1038/s43017-021-00195-3

Misra, A., White, K., Nsutezo, S. F., Straka III, W., & Lavista, J. (2025). Mapping global floods with 10 years of satellite radar data. Nature Communications, 16(1), 5762. https://doi.org/10.1038/s41467-025-60973-1

Mohamadiazar, N., Ebrahimian, A., & Hosseiny, H. (2024). Integrating deep learning, satellite image processing, and spatial-temporal analysis for urban flood prediction. Journal of Hydrology, 639, 131508. https://doi.org/10.1016/j.jhydrol.2024.131508

Munawar, H. S., Hammad, A. W. A., & Waller, S. T. (2022). Remote Sensing Methods for Flood Prediction: A Review. Sensors, 22(3), 960. https://doi.org/10.3390/s22030960

Nagamani, K. T., Bhagwat, T. N., Manjunatha, B. R., & Ramaraju, H. K. (2026). Demarcation and validation of flood susceptibility hazard zone mapping by AHP for the Swarna River Basin, Southern Part of the West Coast India. Discover Applied Sciences, 8(7), 754. https://doi.org/10.1007/s42452-026-08653-7

Nagato, R., Jose, I. K. S., Wiguna, S., Kametaka, R., Adriano, B., Mas, E., vd. (2026). Comparative Analysis of PALSAR-2 and Geographical Features for Mapping Urban and Non-Urban Flooded Areas. Journal of Disaster Research, 21(1), 201. https://doi.org/10.20965/jdr.2026.p0201

Najafi, H., Shrestha, P. K., Rakovec, O., Apel, H., Vorogushyn, S., Kumar, R., vd. (2024). High-resolution impact-based early warning system for riverine flooding. Nature Communications, 15(1), 3726. https://doi.org/10.1038/s41467-024-48065-y

Nearing, G., Cohen, D., Dube, V., Gauch, M., Gilon, O., Harrigan, S., vd. (2024). Global prediction of extreme floods in ungauged watersheds. Nature, 627(8004), 559. https://doi.org/10.1038/s41586-024-07145-1

Nhu, V. H., Ngo, P. T. T., Pham, T. D., Dou, J., Song, X., Hoang, N. D., vd. (2020). A new hybrid firefly-pso optimized random subspace tree intelligence for torrential rainfall-induced flash flood susceptible mapping. Remote Sensing, 12(17), 2688. https://doi.org/10.3390/rs12172688

Noori, A. M., Ziboon, A. R. T., & AL-Hameedawi, A. N. (2025). Deep-Learning Integration of CNN–Transformer and U-Net for Bi-Temporal SAR Flash-Flood Detection. Applied Sciences (Switzerland), 15(14), 7770. https://doi.org/10.3390/app15147770

Piadeh, F., Behzadian, K., & Alani, A. M. (2022). A critical review of real-time modelling of flood forecasting in urban drainage systems. Journal of Hydrology, 607, 127476. https://doi.org/10.1016/j.jhydrol.2022.127476

Pradhan, B., Lee, S., Dikshit, A., & Kim, H. (2023). Spatial flood susceptibility mapping using an explainable artificial intelligence (XAI) model. Geoscience Frontiers, 14(6), 101625. https://doi.org/10.1016/j.gsf.2023.101625

Rafiei-Sardooi, E., Azareh, A., Choubin, B., Mosavi, A. H., & Clague, J. J. (2021). Evaluating urban flood risk using hybrid method of TOPSIS and machine learning. International Journal of Disaster Risk Reduction, 66, 102614. https://doi.org/10.1016/j.ijdrr.2021.102614

Rashid, M., Ullah, S., Farnaz, Farooq, S., Haider, S., Liso, I. S., vd. (2026). Integrated Data-Driven Multi-Criteria Analysis and Machine Learning Approaches for Assessment of Flood Susceptibility Mapping. Water (Switzerland), 18(7), 844. https://doi.org/10.3390/w18070844

Razavi-Termeh, S. V., Sadeghi-Niaraki, A., Razavi, S., & Choi, S. M. (2024). Enhancing flood-prone area mapping: fine-tuning the K-nearest neighbors (KNN) algorithm for spatial modelling. International Journal of Digital Earth, 17(1), 2311325. https://doi.org/10.1080/17538947.2024.2311325

Ren, H., Pang, B., Bai, P., Zhao, G., Liu, S., Liu, Y., vd. (2024). Flood Susceptibility Assessment with Random Sampling Strategy in Ensemble Learning (RF and XGBoost). Remote Sensing, 16(2), 320. https://doi.org/10.3390/rs16020320

Rentschler, J., Salhab, M., & Jafino, B. A. (2022). Flood exposure and poverty in 188 countries. Nature Communications, 13(1), 3527. https://doi.org/10.1038/s41467-022-30727-4

Rezvani, S. M., Gonçalves, A., Silva, M. J. F., & de Almeida, N. M. (2024). Smart hotspot detection using geospatial artificial intelligence: A machine learning approach to reduce flood risk. Sustainable Cities and Society, 115, 105873. https://doi.org/10.1016/j.scs.2024.105873

Roohi, M., Ghafouri, H. R., Ashrafi, S. M., Motagh, M., & Haghshenas Haghighi, M. (2025). A hybrid approach for enhanced flood prediction and assessment: Leveraging physical models, deep learning and satellite remote sensing. Big Earth Data, 9(3), 439. https://doi.org/10.1080/20964471.2025.2530850

Saleh, T., Weng, X., Holail, S., Hao, C., & Xia, G. S. (2024). DAM-Net: Flood detection from SAR imagery using differential attention metric-based vision transformers. ISPRS Journal of Photogrammetry and Remote Sensing, 212, 440. https://doi.org/10.1016/j.isprsjprs.2024.05.018

Sanderson, J., Mao, H., Abdullah, M. A. M., Al-Nima, R. R. O., & Woo, W. L. (2023). Optimal Fusion of Multispectral Optical and SAR Images for Flood Inundation Mapping through Explainable Deep Learning. Information (Switzerland), 14(12), 660. https://doi.org/10.3390/info14120660

Sarkar, S. K., Ansar, S. B., Ekram, K. M. M., Khan, M. H., Talukdar, S., Naikoo, M. W., vd. (2022). Developing Robust Flood Susceptibility Model with Small Numbers of Parameters in Highly Fertile Regions of Northwest Bangladesh for Sustainable Flood and Agriculture Management. Sustainability (Switzerland), 14(7), 3982. https://doi.org/10.3390/su14073982

Seydi, S. T., Kanani-Sadat, Y., Hasanlou, M., Sahraei, R., Chanussot, J., & Amani, M. (2023). Comparison of Machine Learning Algorithms for Flood Susceptibility Mapping. Remote Sensing, 15(1), 192. https://doi.org/10.3390/rs15010192

Shampa, Nasir, N. N., Winey, M. M., Dey, S., Zahid, S. M. T., Tasnim, Z., vd. (2025). Integration of Remote Sensing and Machine Learning Approaches for Operational Flood Monitoring Along the Coastlines of Bangladesh Under Extreme Weather Events. Water (Switzerland), 17(15), 2189. https://doi.org/10.3390/w17152189

Shastry, A., Carter, E., Coltin, B., Sleeter, R., McMichael, S., & Eggleston, J. (2023). Mapping floods from remote sensing data and quantifying the effects of surface obstruction by clouds and vegetation. Remote Sensing of Environment, 291, 113556. https://doi.org/10.1016/j.rse.2023.113556

Shirzadi, A., Salvati, A., Tahan, M. H., Shahabi, H., Nodoushan, E. J., Ramezani, M., vd. (2025). Urban flood susceptibility mapping using deep and machine learning algorithms as a management tool: A case study of Sanandaj City, Iran. Ecological Indicators, 178, 113886. https://doi.org/10.1016/j.ecolind.2025.113886

Sibandze, P., Kalumba, A. M., & Afuye, G. A. (2026). A systematic review of geospatial and meteorological approaches to flood risk assessment and monitoring. Environmental Earth Sciences, 85(16), 425. https://doi.org/10.1007/s12665-026-13155-1

Simonovic, S. P., & Perry, B. (2025). Local Scale Current and Projected Future Total Flood Hazard Mapping for Canada—Literature Review. Journal of Flood Risk Management, 18(3), e70091. https://doi.org/10.1111/jfr3.70091

Singh, R. K., Soni, A., Kumar, S., Pasupuleti, S., & Govind, V. (2021). Zonation of flood prone areas by an integrated framework of a hydrodynamic model and ANN. Water Science and Technology: Water Supply, 21(1), 80. https://doi.org/10.2166/ws.2020.252

Tate, E., Rahman, M. A., Emrich, C. T., & Sampson, C. C. (2021). Flood exposure and social vulnerability in the United States. Natural Hazards, 106(1), 435. https://doi.org/10.1007/s11069-020-04470-2

Tella, A., Pham, Q. B., Zahidi, I., Fai, C. M., & Ibrahim, K. S. M. H. (2026). Advancing Flood Susceptibility Mapping with Explainable AI: A Novel Application of Accumulated Local Effects (ALE). Water Resources Management, 40(4), 140. https://doi.org/10.1007/s11269-025-04430-0

Tellman, B., Sullivan, J. A., Kuhn, C., Kettner, A. J., Doyle, C. S., Brakenridge, G. R., vd. (2021). Satellite imaging reveals increased proportion of population exposed to floods. Nature, 596(7870), 80. https://doi.org/10.1038/s41586-021-03695-w

Truu, M., Annus, I., Roosimägi, J., Kändler, N., Vassiljev, A., & Kaur, K. (2021). Integrated decision support system for pluvial flood-resilient spatial planning in urban areas. Water (Switzerland), 13(23), 3340. https://doi.org/10.3390/w13233340

Tsangaratos, P., Ilia, I., Chrysafi, A. A., Matiatos, I., Chen, W., & Hong, H. (2023). Applying a 1D Convolutional Neural Network in Flood Susceptibility Assessments—The Case of the Island of Euboea, Greece. Remote Sensing, 15(14), 3471. https://doi.org/10.3390/rs15143471

Vojtek, M., Benko, Ľ., Kapusta, J., Držík, D., Munk, M., Munková, D., vd. (2026). High-resolution dataset (2017-2023) of physical-geographical predictors for machine learning modelling of fluvial

flooding: the Gidra river case, Slovakia. Data in Brief, 64, 112321. https://doi.org/10.1016/j.dib.2025.112321

Vojtek, M., Vojteková, J., Costache, R., Pham, Q. B., Lee, S., Arshad, A., vd. (2021). Comparison of multi-criteria-analytical hierarchy process and machine learning-boosted tree models for regional flood susceptibility mapping: a case study from Slovakia. Geomatics, Natural Hazards and Risk, 12(1), 1153. https://doi.org/10.1080/19475705.2021.1912835

Vongkusolkit, J., Peng, B., Wu, M., Huang, Q., & Andresen, C. G. (2023). Near Real-Time Flood Mapping with Weakly Supervised Machine Learning. Remote Sensing, 15(13), 3263. https://doi.org/10.3390/rs15133263

Waleed, M., & Sajjad, M. (2025). Advancing flood susceptibility prediction: A comparative assessment and scalability analysis of machine learning algorithms via artificial intelligence in high-risk regions of Pakistan. Journal of Flood Risk Management, 18(1), e13047. https://doi.org/10.1111/jfr3.13047

Wang, L., Cui, S., Li, Y., Huang, H., Manandhar, B., Nitivattananon, V., vd. (2022). A review of the flood management: from flood control to flood resilience. Heliyon, 8(11), e11763. https://doi.org/10.1016/j.heliyon.2022.e11763

Wang, M., Li, Y., Yuan, H., Zhou, S., Wang, Y., Ikram, R. M. A., vd. (2023). An XGBoost-SHAP approach to quantifying morphological impact on urban flooding susceptibility. Ecological Indicators, 156, 111137. https://doi.org/10.1016/j.ecolind.2023.111137

Wang, Z., Lyu, H., & Zhang, C. (2023). Pluvial flood susceptibility mapping for data-scarce urban areas using graph attention network

and basic flood conditioning factors. Geocarto International, 38(1), 2275692. https://doi.org/10.1080/10106049.2023.2275692

Wasie, Y. Y., Ho, C. C., Yang, P. Y., Kassa, D. A., & Lin, J. Y. (2026). GIS and remote sensing-based hybrid AHP–machine learning framework for flood susceptibility and risk assessment in the Wolaita Zone, Southern Ethiopia. Geomatics, Natural Hazards and Risk, 17(1), 2689851. https://doi.org/10.1080/19475705.2026.2689851

Wing, O. E. J., Lehman, W., Bates, P. D., Sampson, C. C., Quinn, N., Smith, A. M., vd. (2022). Inequitable patterns of US flood risk in the Anthropocene. Nature Climate Change, 12(2), 156. https://doi.org/10.1038/s41558-021-01265-6

Xu, K., Han, Z., Xu, H., & Bin, L. (2023). Rapid Prediction Model for Urban Floods Based on a Light Gradient Boosting Machine Approach and Hydrological-Hydraulic Model. International Journal of Disaster Risk Science, 14(1), 79. https://doi.org/10.1007/s13753-023-00465-2

Yan, C., Wu, L., Huang, P., Yue, J., Li, H., Zhou, C., vd. (2026). Mitigating Overfitting and Physical Inconsistency in Flood Susceptibility Mapping: A Physics-Constrained Evolutionary Machine Learning Framework for Ungauged Alpine Basins. Water (Switzerland), 18(7), 882. https://doi.org/10.3390/w18070882

Yang, A., Li, W., Gao, P., Fan, Y., & Wang, X. (2026). Development of PXB-BVC Framework for Multivariate Flood-Risk Assessment Under Climate Change. Remote Sensing, 18(14), 2275. https://doi.org/10.3390/rs18142275

Yan, Y., Zhang, N., & Zhang, H. (2023). Applications of Advanced Technologies in the Development of Urban Flood Models. Water (Switzerland), 15(4), 622. https://doi.org/10.3390/w15040622

Yao, X., Yang, L., Tan, J., Xie, Z., Gan, C., Wen, P., vd. (2026). Bayesian-optimized BiLSTM-U-Net framework for urban flood prediction with spatio-temporal feature integration. Journal of Hydrology, 669, 135175. https://doi.org/10.1016/j.jhydrol.2026.135175

Yin, Y., Zhang, X., Guan, Z., Chen, Y., Liu, C., & Yang, T. (2023). Flash flood susceptibility mapping based on catchments using an improved Blending machine learning approach. Hydrology Research, 54(4), 557. https://doi.org/10.2166/nh.2023.139

Zhang, W., Hu, B., Liu, Y., Zhang, X., & Li, Z. (2023). Urban Flood Risk Assessment through the Integration of Natural and Human Resilience Based on Machine Learning Models. Remote Sensing, 15(14), 3678. https://doi.org/10.3390/rs15143678

Zheng, W., Huang, H., Li, J., & Liu, Z. (2026). Weakly Supervised Multimodal Fusion of Remote Sensing and Social Media Data for Urban Flood Mapping. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 19, 14219. https://doi.org/10.1109/jstars.2026.3680591

Zhu, J., Dang, P., Cao, Y., Lai, J., Guo, Y., Wang, P., vd. (2024). A flood knowledge-constrained large language model interactable with GIS: enhancing public risk perception of floods. International Journal of Geographical Information Science, 38(4), 603. https://doi.org/10.1080/13658816.2024.2306167

BÖLÜM 2

ORMAN YANGINI SONRASI YANMA ŞİDDETİNİN SPEKTRAL İNDEKSLER VE MAKİNE ÖĞRENMESİYLE ANALİZİ: SEYDİKEMER (MUĞLA) ÖRNEĞİ

DUYGU MİNAZ[1]

Giriş

Orman yangınları, biyolojik çeşitlilik, toprak özellikleri, karbon döngüsü ve hidrolojik süreçler üzerinde kısa ve uzun vadeli etkiler oluşturarak ekosistemlerin yapısını ve işleyişini değiştiren önemli çevresel afetlerdir (Bowman vd., 2009; Keeley vd., 2012). Küresel iklim değişikliğine bağlı sıcaklık artışları ve kuraklaşma eğilimleri, özellikle Akdeniz iklim kuşağında yangın tehlikesinin artmasına ve gelecekte yanmış alanların genişlemesine neden olabilecek önemli etmenler arasında değerlendirilmektedir (Dupuy vd., 2020; Rovithakis vd., 2022). Yangın sonrası yanma şiddetinin mekânsal olarak belirlenmesini ekosistem restorasyonu, orman kaynaklarının yönetimi, toprak ve su kaynaklarının korunması ile karbon kayıplarının değerlendirilmesi açısından gerekli kılmaktadır (Madiba vd., 2026). Türkiye, Akdeniz Havzası'ndaki coğrafi konumu ve iklim özellikleri nedeniyle orman yangınlarına karşı

[1] Dr., Bağımsız Araştırmacı, Orcid: 0000-0003-3274-957X

yüksek duyarlılığa sahip olup, özellikle Ege ve Akdeniz bölgelerinde yayılış gösteren kızılçam (*Pinus brutia*) ormanları yüksek reçine içeriği ve kolay tutuşabilen örtü tabakası nedeniyle yangınların hızla yayılmasına elverişli özellikler göstermektedir (Bilgili vd., 2010; Sağlam vd., 2008). Yüksek sıcaklık, düşük nem, kuraklık ve kuvvetli rüzgârın birlikte etkili olduğu Muğla gibi Akdeniz ikliminin hâkim olduğu illerde yangın sonrası etkilerin ayrıntılı olarak değerlendirilmesi büyük önem taşımakta olup, 2021 yılında meydana gelen geniş ölçekli yangınlar ve sonraki yıllarda yaşanan olaylar bölgenin yangınlara karşı yüksek duyarlılığını açıkça ortaya koymuştur.

29 Temmuz 2026 tarihinde Muğla ilinin Seydikemer ilçesinde meydana gelen orman yangını, güncel bir araştırma örneği oluşturmaktadır. Muğla Valiliği'nin 2026 yılı Orman Yangınlarıyla Mücadele Kararı'nda, Seydikemer ve çevresindeki orman alanlarının Akdeniz iklimi, hâkim rüzgâr özellikleri ile kızılçam (*Pinus brutia*) ve Toros sediri (*Cedrus libani*) ormanlarının yayılışı nedeniyle yangın açısından hassas bölgeler arasında yer aldığı belirtilmektedir (Muğla Valiliği, 2026). Bu özellikleriyle Seydikemer yangını, yanma şiddetinin mekânsal dağılımı ile bunu etkileyen çevresel faktörlerin birlikte değerlendirilmesi açısından uygun bir çalışma alanı sunmaktadır.

Yangın sonrası etkilerin geniş alanlarda hızlı ve nesnel biçimde belirlenmesinde uzaktan algılama teknikleri önemli avantajlar sağlayabilmektedir. Uydu görüntüleri, yangın öncesi ve sonrası yüzey özelliklerindeki değişimlerin mekânsal olarak ortaya konulmasına olanak sağlarken, Sentinel-2 10–20 m mekânsal çözünürlüğe sahip multispektral bantları ve yüksek zamansal tekrar kapasitesi, yangın sonrası vejetasyon değişimlerinin ayrıntılı olarak belirlenmesini mümkün kılmaktadır (Key & Benson, 2006).

Yanma şiddetinin belirlenmesinde NBR, dNBR ve RdNBR indeksleri yaygın olarak kullanılmakta, ancak tek bir spektral indeks

karmaşık yüzey değişimlerini her zaman yeterince yansıtamamaktadır. Bu nedenle NBR tabanlı göstergelerin NDVI ve dNDVI gibi vejetasyon indeksleriyle birlikte kullanılması, yangın kaynaklı değişimlerin daha kapsamlı değerlendirilmesini sağlamaktadır (Miller & Thode, 2007).

Uzaktan algılama verilerinin analizinde yaygın olarak kullanılan Random Forest (RF), yüksek boyutlu verilerle çalışabilmesi, doğrusal olmayan ilişkileri modelleyebilmesi ve değişken önemini belirleyebilmesi nedeniyle öne çıkmaktadır (Breiman, 2001; Belgiu & Drăguţ, 2016). Bu özellikleri sayesinde RF, orman yangınlarının haritalanması ve yanık alanların sınıflandırılmasında yüksek doğruluk sağlayan makine öğrenmesi algoritmalarından biri olarak yaygın şekilde kullanılmaktadır. Yangın sonrası yanma şiddetinin belirlenmesinde kullanılan spektral indeksler, vejetasyonda meydana gelen değişimlerin ortaya konulmasında önemli göstergeler sunmaktadır. Bununla birlikte, yanma şiddetinin mekânsal dağılımının değerlendirilmesinde spektral göstergelerin yanı sıra meteorolojik koşulların da dikkate alınması gerekmektedir. Sıcaklık, bağıl nem, yağış ve rüzgâr gibi meteorolojik değişkenler, yangın tehlikesini ve yangının yayılımını etkileyen temel çevresel faktörler arasında yer almaktadır (Jolly vd., 2015; Abatzoglou & Williams, 2016). Bu çalışmada kullanılan ERA5-Land veri seti, yangın dönemindeki meteorolojik koşulların incelenmesine olanak sağlamaktadır (Muñoz Sabater vd., 2021).

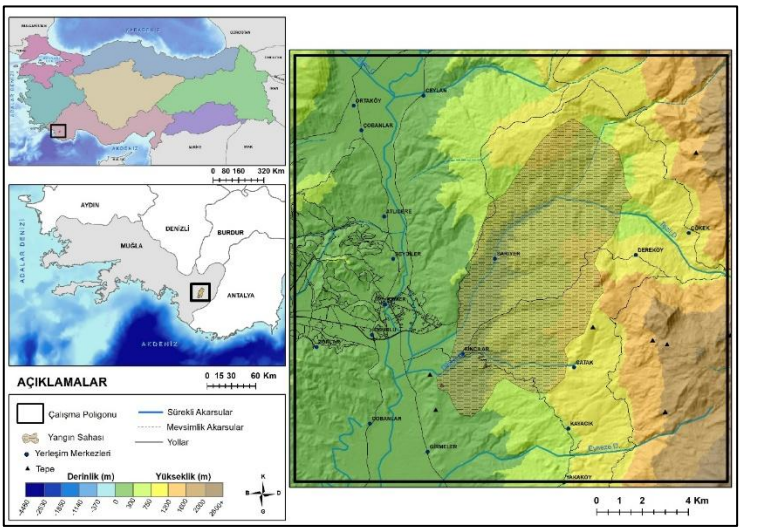
Bu kitap bölümünde, 29 Temmuz 2026 tarihinde Muğla'nın Seydikemer ilçesinde meydana gelen orman yangınının yanma şiddeti, Sentinel-2 uydu görüntülerinden türetilen NDVI, NBR, dNDVI, dNBR ve RdNBR indeksleri kullanılarak değerlendirilmiştir. Spektral indekslerin yanık alanların belirlenmesindeki katkısı Random Forest algoritmasıyla analiz edilmiş, yangın sürecindeki meteorolojik koşullar ERA5-Land verileri üzerinden incelenmiştir. Bu doğrultuda, spektral göstergeler

ve meteorolojik veriler birlikte ele alınarak yangın sonrası yanma şiddetinin mekânsal dağılımının ortaya konulması amaçlanmıştır

Çalışma Alanının Coğrafi Özellikleri

Araştırma sahası, Türkiye'nin güneybatısında yer alan Muğla iline bağlı Seydikemer ilçesi sınırları içerisinde bulunmaktadır. Seydikemer, 6360 Sayılı Kanun kapsamında ilçe statüsü kazanmış olup yaklaşık 36°20′–36°55′ kuzey enlemleri ile 28°35′–29°25′ doğu boylamları arasında yer almaktadır (Resmî Gazete, 2012). Söz konusu ilçe, Akdeniz Bölgesi'nin batı kesiminde ve Teke Yarımadası'nın kuzeybatısında konumlanmaktadır. Seydikemer'in batısında Fethiye, doğusunda Antalya'nın Kaş ilçesi, kuzeyinde Denizli ve Burdur illeri, güneyinde ise Akdeniz bulunmaktadır (Şekil 1).

Şekil 1 Çalışma alanının lokasyon haritası



Seydikemer, Batı Toros Dağları'nın güneybatı uzantıları üzerinde yer almakta olup kıyı ovaları ile dağlık alanların bir arada bulunduğu engebeli bir topografyaya sahiptir. Çalışma sahasında yükselti yaklaşık 0–2600 m arasında değişmekte; buna bağlı olarak

eğim ve bakı özellikleri de kısa mesafelerde önemli farklılıklara sahiptir.

Araştırma sahası, tipik Akdeniz ikliminin etkisi altında olup yazları sıcak ve kurak, kışları ise ılık ve yağışlıdır. Meteoroloji Genel Müdürlüğü uzun yıllar ortalamalarına göre Muğla ilinde yıllık ortalama sıcaklık 15,4 °C, ortalama en yüksek sıcaklık 22,0 °C, ortalama en düşük sıcaklık 9,9 °C, yıllık ortalama toplam yağış miktarı ise 1165,2 mm'dir (T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Meteoroloji Genel Müdürlüğü.). Özellikle temmuz ve ağustos aylarında yüksek sıcaklık, düşük yağış ve azalan bağıl nem koşulları nedeniyle bitki örtüsünün nem içeriği azalmakta ve yangınların başlaması ile yayılması için elverişli bir ortam oluşmaktadır.

Çalışma alanının doğal bitki örtüsü ağırlıklı olarak Akdeniz orman ekosistemlerinden oluşmaktadır. Bozyiğit'in (2020) aktardığına göre, çalışma alanında yükselti arttıkça bitki örtüsü belirgin biçimde değişmektedir. Yaklaşık 1000 m'nin üzerindeki yükseltilerde maki toplulukları yerini kızılçam (*Pinus brutia*), Toros göknarı (*Abies cilicica*) ve meşe (*Quercus spp.*) türlerinin oluşturduğu ormanlara bırakmaktadır. Yaklaşık 1300–1450 m arasında karaçam- meşe karışık ormanları, 1450–2000 m yükseltilerde Toros sediri (*Cedrus libani*) ve 2000–2200 m arasında ise adi ardıç (*Juniperus communis*) toplulukları yayılış göstermektedir. Reçineli yapıya sahip kızılçam ormanları ve yoğun maki formasyonları, yüksek yanıcılık özellikleri nedeniyle yangının hızlı yayılmasına elverişli bir yakıt ortamı oluşturmaktadır (Şekil 2-3-4-5). Orman alanlarının yanı sıra tarım arazileri, zeytinlikler, seralar ve kırsal yerleşim alanları da arazi kullanım ve arazi örtüsü deseninin önemli bileşenlerini oluşturmaktadır.

Şekil 2 Seydikemer orman yangınında yangının yayılımı ve müdahale çalışmaları



Şekil 3 Seydikemer orman yangını sonrasında zarar gören orman alanları



Şekil 4 Seydikemer orman yangınına ilişkin görünüm



Şekil 5 Seydikemer orman yangınının gündüz saatlerindeki görünümü (29 Temmuz 2026)



Veri ve Yöntem

Veri Setleri

Araştırma sahasına ait lokasyon haritası, Copernicus DEM GLO-30 (30 m) sayısal yükseklik modeli kullanılarak ArcGIS 10.8 yazılımında oluşturulmuştur. Yangın öncesi ve yangın sürecindeki meteorolojik koşulların değerlendirilmesinde ise ERA5-Land Daily Aggregated yeniden analiz veri setinden elde edilen günlük sıcaklık, toplam yağış ve rüzgâr hızı verileri kullanılmıştır. Sentinel-2 görüntülerinin ön işlenmesi, spektral indekslerin hesaplanması ve meteorolojik verilerin elde edilmesi işlemleri Google Earth Engine (GEE) bulut tabanlı platformunda gerçekleştirilmiştir (Gorelick vd., 2017; Tablo 1).

Tablo 1 Çalışmada kullanılan uzaktan algılama ve yardımcı veri setleri

Veri Seti	Mekânsal Çözünürlük	Kullanım Amacı	İşlem Ortamı
Sentinel-2 Level-2A	10–20 m	NDVI, NBR, dNDVI, dNBR, RdNBR hesaplamaları	Google Earth Engine
Copernicus DEM GLO-30	30 m	Lokasyon	ArcGIS 10.8
ERA5-Land Daily Aggregated	11 km	Günlük sıcaklık, bağıl nem, yağış ve rüzgâr verileri	Google Earth Engine

Sentinel-2 Görüntülerinin Ön İşlenmesi

Bu çalışmada, 29 Temmuz 2026 tarihinde Muğla ili Seydikemer ilçesinde meydana gelen orman yangınının öncesi ve sonrası arazi örtüsü değişimlerinin belirlenmesi amacıyla Copernicus Sentinel-2 Level-2A (Surface Reflectance) uydu görüntüleri kullanılmıştır. Sentinel-2, yüksek mekânsal çözünürlüklü multispektral bantları sayesinde orman yangınlarının izlenmesinde yaygın olarak kullanılmaktadır (Drusch vd., 2012).

Yangın öncesi dönem için 20–29 Temmuz 2026, yangın sonrası dönem için ise 30 Temmuz–05 Ağustos 2026 tarihleri arasındaki görüntüler kullanılmıştır. Bulut etkisini en aza indirmek amacıyla görüntülerde Cloudy Pixel Percentage <%10 kriteri uygulanmış ve Sentinel-2'nin Scene Classification Layer (SCL) bandı kullanılarak gölge, bulut, ince bulut ve kar pikselleri maskelenmiştir. Daha sonra her dönem için medyan kompozit görüntü oluşturulmuştur (Tablo 2).

Tablo 2 Yangın öncesi ve sonrası Sentinel-2 görüntülerine ilişkin bilgiler

Veri	Görüntü Tarihi	Uydu	Ürün Seviyesi	Mekânsal Çözünürlük	Kullanılan Bantlar
Yangın öncesi Sentinel-2 görüntüsü	20–29 Temmuz 2026 (medyan kompozit)	Sentinel-2A/2B MSI	Level-2A (Surface Reflectance)	10 m (B4, B8), 20 m (B12)	B4 (Kırmızı), B8 (Yakın Kızılötesi), B12 (Kısa Dalga Kızılötesi)
Yangın sonrası Sentinel-2 görüntüsü	30 Temmuz-05 Ağustos 2026 (medyan kompozit)	Sentinel-2A/2B MSI	Level-2A (Surface Reflectance)	10 m (B4, B8), 20 m (B12)	B4 (Kırmızı), B8 (Yakın Kızılötesi), B12 (Kısa Dalga Kızılötesi)

Spektral İndekslerin Hesaplanması

Orman yangınının vejetasyon üzerindeki etkilerini belirlemek amacıyla yangın öncesi ve sonrası Sentinel-2 görüntülerinden NDVI, NBR, dNDVI, dNBR ve RdNBR indeksleri hesaplanmıştır. Bu indeksler, bitki örtüsü değişimi, biyokütle kaybı ve yanma şiddetinin belirlenmesinde yaygın olarak kullanılmaktadır (Rouse vd., 1974; Key & Benson, 2006; Miller & Thode, 2007).

NDVI, vejetasyon yoğunluğu ve canlılığını belirlemek amacıyla Sentinel-2 Band 8 (NIR) ile Band 4 (Kırmızı) kullanılarak aşağıdaki eşitliğe göre hesaplanmıştır (Rouse vd., 1974) (1):

(1)

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

Yangın öncesi ve sonrası dönemlere ait NDVI haritaları karşılaştırılarak vejetasyon yoğunluğundaki değişimler değerlendirilmiştir.

NBR, yangın sonrası bitki örtüsü kaybı ve yanık alanların belirlenmesinde yaygın olarak kullanılan bir spektral indekstir (Key & Benson, 2006). İndeks, yakın kızılötesi (Band 8) ile kısa dalga kızılötesi (Band 12) bantlarının normalize edilmiş farkına dayanmaktadır (2).

(2)

$$NBR = \frac{NIR - SWIR}{NIR + SWIR}$$

Formülde (2) NIR, Sentinel-2 Band 8, SWIR ise Band 12'yi ifade etmektedir. Yangın sonrası bitki örtüsünün zarar görmesiyle birlikte NBR değerlerinde belirgin düşüşler meydana gelmektedir.

Yangının vejetasyon üzerindeki etkisini belirlemek amacıyla yangın öncesi ve sonrası NDVI görüntülerinin farkı alınarak dNDVI hesaplanmıştır (3).

(3)

$$\Delta NDVI = NDVI_{before} - NDVI_{after}$$

Pozitif dNDVI değerleri, yangın sonrası vejetasyon yoğunluğunda meydana gelen azalmayı ve bitki örtüsü kaybını ifade ederken, düşük veya negatif değerler değişimin sınırlı olduğunu ortaya koymaktadır.

Yanma şiddetinin uzaktan algılama verileriyle değerlendirilmesinde en yaygın kullanılan göstergelerden biri olan dNBR, yangın öncesi ve sonrası NBR görüntülerinin farkı alınarak hesaplanmıştır (Key & Benson, 2006) (4).

(4)

$$\Delta NBR = NBR_{\{before\}} - NBR_{\{after\}}$$

dNBR değerlerinin artması, yangının bitki örtüsü üzerinde oluşturduğu etkinin ve yanma şiddetinin arttığını göstermektedir. Bu indeks, yanık alanların sınıflandırılması ve yanma şiddetinin mekânsal yayılışının belirlenmesinde temel gösterge olarak kullanılmıştır. Farklı başlangıç vejetasyon yoğunluklarının dNBR üzerindeki etkisini azaltmak amacıyla Relative differenced Normalized Burn Ratio (RdNBR) hesaplanmıştır (Miller & Thode, 2007). RdNBR, dNBR değerlerinin yangın öncesi NBR değerine göre normalize edilmesi esasına dayanmaktadır (5).

(5)

$$RdNBR = \frac{dNBR}{\sqrt{|NBR_{before}|}}$$

dNBR Tabanlı Yanma Şiddetinin Belirlenmesi

Yanma şiddetinin belirlenmesinde dNBR indeksi esas alınmıştır. dNBR rasteri Key & Benson (2006) tarafından önerilen eşik değerler dikkate alınarak dört sınıfa ayrılmıştır (Tablo 3).

Tablo 3 dNBR eşik değerlerine göre yanma şiddeti sınıflandırması

dNBR	Yanma Şiddeti
<0.10	Yanmamış / Çok Düşük
0.10–0.27	Düşük
0.27–0.44	Orta
>0.44	Yüksek

** Her sınıfa ait alanlar piksel alanı yöntemi kullanılarak hektar (ha) cinsinden hesaplanmıştır.*

dNBR değerleri, belirlenen yanma şiddeti eşiklerine göre sınıflandırılmış ve her sınıfın kapladığı alan hektar (ha) ve kilometrekare (km²) cinsinden hesaplanmıştır. Sınıfların toplam alan içerisindeki yüzdesel dağılımları da hesaplanarak yanma şiddetinin mekânsal dağılımı değerlendirilmiştir. Elde edilen alan değerleri, çalışmada kullanılan uydu görüntüleri ve uygulanan sınıflandırma yöntemi doğrultusunda üretilen araştırma bulgularıdır; resmî kurumlar tarafından açıklanan yangın hasar verilerini temsil etmemektedir.

Random Forest Tabanlı Değişken Önem Analizi

Random Forest (RF), yüksek boyutlu verileri etkin biçimde işleyebilmesi ve değişken önem analizini sağlayabilmesi nedeniyle uzaktan algılama ve orman yangını çalışmalarında yaygın olarak

kullanılan bir makine öğrenmesi algoritmasıdır (Breiman, 2001; Belgiu & Drăguţ, 2016). Bu çalışmada RF, yangın öncesi ve sonrası hesaplanan NDVI, NBR, dNDVI, dNBR ve RdNBR indekslerinin yanık alanların belirlenmesine katkısını değerlendirmek amacıyla uygulanmıştır. Analizde, Sentinel-2 görüntüleri üzerinden manuel olarak belirlenen 150 yanık ve 150 yanmamış olmak üzere toplam 300 referans örneği kullanılmıştır. Referans örnekleri, yanık ve yanmamış alanları temsil edecek biçimde seçilmiş; örneklerin çalışma alanındaki mekânsal dağılımı, farklı yanma durumlarının ve yüzey özelliklerinin temsil edilebilirliği açısından değerlendirilmiştir. Veriler, modelin eğitimi ve performansının test edilmesi amacıyla %70 eğitim (n = 215) ve %30 test (n = 85) gruplarına ayrılmıştır. Model, Google Earth Engine ortamında 500 karar ağacı kullanılarak oluşturulmuş; performansı hata matrisi, genel doğruluk, Kappa katsayısı, üretici ve kullanıcı doğrulukları üzerinden değerlendirilmiştir. Ayrıca spektral indekslerin göreli değişken önem değerleri hesaplanmıştır. RF modeli, yanık alanların mekânsal dağılımını bağımsız bir harita olarak üretmek yerine, kullanılan spektral indekslerin yanık alanların ayırt edilmesine katkısını ve sınıflandırma performansını değerlendirmek amacıyla kullanılmıştır. Bu doğrultuda model çıktıları, spektral indekslerin ayırt edicilik düzeylerinin karşılaştırılması ve değişken önemlerinin belirlenmesi amacıyla değerlendirilmiştir.

Yangın Dönemine Ait Meteorolojik Koşulların Analizi

Orman yangınlarının oluşumu ve yayılımında sıcaklık, yağış ve rüzgâr gibi meteorolojik faktörler önemli rol oynamaktadır (Chuvieco vd., 2014). Bu nedenle yangın öncesi ve yangın dönemindeki meteorolojik koşullar, ERA5-Land Daily Aggregated yeniden analiz veri seti kullanılarak değerlendirilmiştir (Muñoz Sabater vd., 2021). Meteorolojik analizlerde, 20 Temmuz–01 Ağustos 2026 dönemine ait 2 m hava sıcaklığı, toplam yağış, bağıl nem ve 10 m rüzgâr hızı verileri Google Earth Engine (GEE)

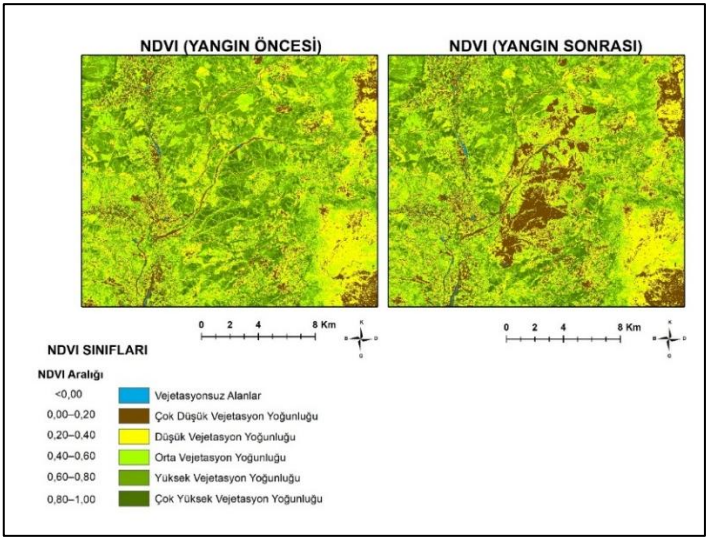
platformundan elde edilmiştir. Veriler uygun birim dönüşümleri yapılarak günlük ortalama değerlere dönüştürülmüş, sıcaklık, yağış ve rüzgâr hızındaki zamansal değişimler analiz edilerek yangının gelişimiyle ilişkisi değerlendirilmiştir.

Bulgular

Yangın Öncesi ve Sonrası NDVI Değişiminin Değerlendirilmesi

Şekil 6'da çalışma alanına ait yangın öncesi ve sonrası NDVI haritaları sunulmaktadır. Yangın öncesinde çalışma alanının büyük bölümü orta (0,40–0,60), yüksek (0,60–0,80) ve çok yüksek (0,80–1,00) NDVI sınıflarında yer almakta olup, bu durum özellikle ormanlık alanlarda sağlıklı ve yoğun bitki örtüsünün hâkim olduğunu göstermektedir. Yangın sonrasında ise yangından etkilenen alanlarda NDVI değerleri belirgin biçimde azalmış, yüksek ve çok yüksek NDVI sınıflarındaki alanların önemli bir bölümü düşük ve orta NDVI sınıflarına dönüşmüştür. Bu değişim özellikle çalışma alanının orta kesiminde yoğunlaşırken, yangından etkilenmeyen çevre kesimlerde yüksek NDVI değerlerinin büyük ölçüde korunduğu görülmektedir. Elde edilen bulgular, yangının vejetasyon yoğunluğu ve canlılığında önemli bir azalmaya neden olduğunu ortaya koymaktadır.

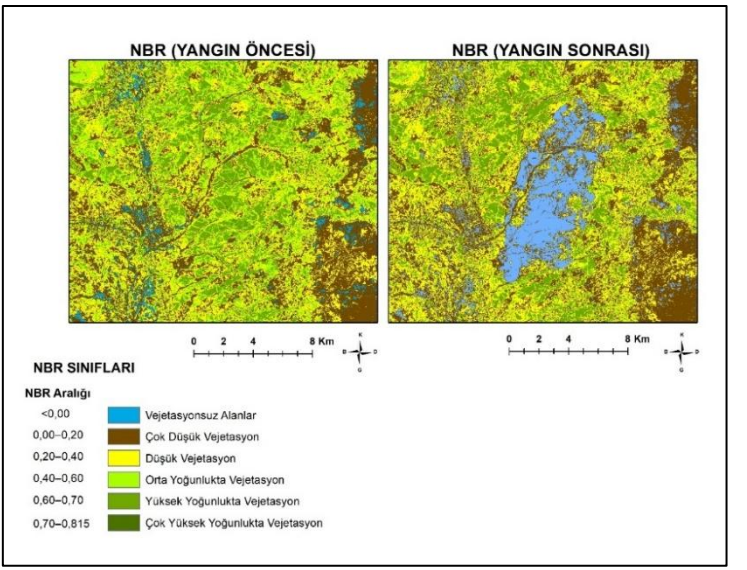
Şekil 6 Yangın öncesi ve sonrası NDVI değişiminin mekânsal görünümü



Yangın Öncesi ve Sonrası NBR Değişiminin Değerlendirilmesi

Şekil 7'de çalışma alanına ait yangın öncesi ve sonrası NBR haritaları sunulmaktadır. Yangın öncesinde sahanın büyük bölümü orta, yüksek ve çok yüksek NBR değerlerine sahip olup, özellikle ormanlık alanlarda yüksek NBR değerleri sağlıklı bitki örtüsünü yansıtmaktadır. Düşük NBR değerleri ise daha çok yerleşim alanları, tarım arazileri, açıklıklar ve seyrek bitki örtüsünün olduğu alanlarda görülmektedir. Yangın sonrası etkilenen alanlarda NBR değerleri belirgin biçimde azalmış, özellikle orta ve kuzeydoğu kesimlerinde yüksek NBR sınıfları düşük değerlere dönüşerek bitki örtüsündeki tahribatı ortaya koymuştur. Buna karşın yangından etkilenmeyen alanlarda orta ve yüksek NBR değerleri büyük ölçüde korunmuştur. Bu sonuçlar, NBR indeksinin yanık alanların belirlenmesinde yüksek ayırt ediciliğe sahip olduğunu ortaya koymaktadır.

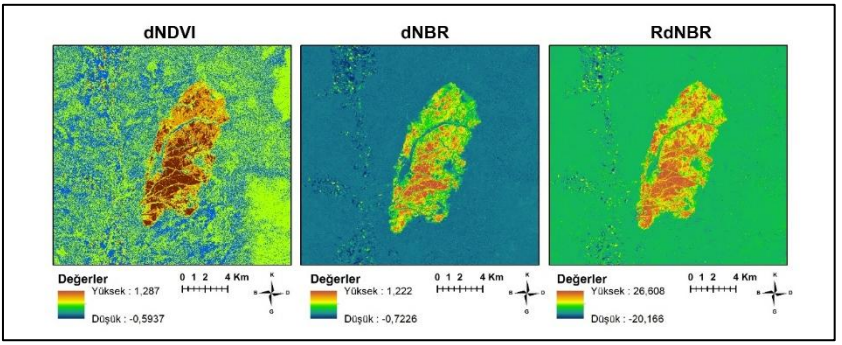
Şekil 7 Yangın öncesi ve sonrası NBR değişiminin mekânsal görünümü



dNDVI, dNBR ve RdNBR Değişimlerinin Değerlendirilmesi

Şekil 8'de çalışma alanına ait dNDVI, dNBR ve RdNBR değişim haritaları sunulmaktadır. Üç indeks de yangın öncesi ve sonrası arasındaki spektral değişimi ortaya koymakta; yüksek değişim değerleri özellikle yangından etkilenen merkez kesimlerde, düşük değerler ise yangından etkilenmeyen alanlarda yoğunlaşmaktadır. İndeksler yanık alanların belirlenmesinde benzer sonuçlar vermekle birlikte, dNDVI vejetasyondaki değişimi, dNBR yanık alanları, RdNBR ise yangın öncesi vejetasyon koşullarını dikkate alarak yanma şiddetini daha güvenilir biçimde ortaya koymaktadır.

Şekil 8 Araştırma sahasının dNDVI, dNBR ve RdNBR haritaları



Tanımlayıcı istatistikler, yangın sonrası spektral değişimi desteklemektedir. Ortalama NDVI değeri 0,497'den 0,448'e, ortalama NBR değeri ise 0,289'dan 0,230'a düşmüştür. Değişim indekslerinin ortalama değerleri dNDVI için 0,049, dNBR için 0,059 ve RdNBR için 0,091 olarak hesaplanmış olup, dNBR ve RdNBR'deki geniş değer aralıkları ile yüksek standart sapmalar yangın etkisinin araştırma sahasında farklı şiddetlerde gerçekleştiğini ortaya çıkarmaktadır (Tablo 4).

Tablo 4 Çalışmada kullanılan spektral indekslere ait tanımlayıcı istatistikler

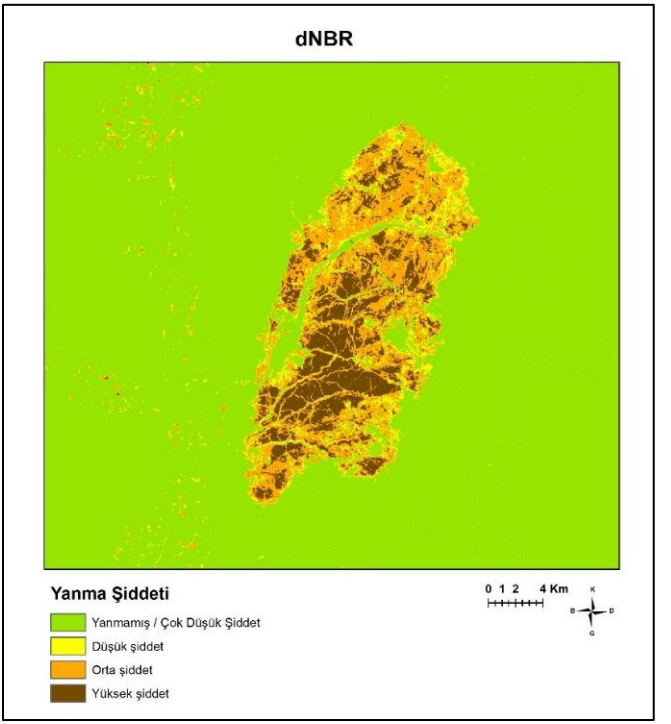
Spektral İndeks	Minimum	Maksimum	Ortalama	Standart Sapma
NDVI (Yangın Öncesi)	-0,824	1,000	0,497	0,226
NDVI (Yangın Sonrası)	-1,000	1,000	0,448	0,237
NBR (Yangın Öncesi)	-0,883	0,811	0,289	0,179
NBR (Yangın Sonrası)	-1,000	0,815	0,230	0,225
dNDVI	-0,593	1,287	0,049	0,147
dNBR	-0,723	1,222	0,059	0,199
RdNBR	-20,166	26,609	0,091	0,351

Tablo 5'te Seydikemer orman yangınına ilişkin dNBR tabanlı yanma şiddeti sınıflarının alansal dağılımı sunulmaktadır. Analiz sonuçlarına göre çalışma alanının 368,20 km²'lik (%87,04) bölümü yanmamış veya çok düşük şiddette etkilenmiştir. Yangından etkilenen alanlar içerisinde düşük şiddet sınıfı 11,94 km² (%2,82), orta şiddet sınıfı 27,15 km² (%6,42) ve yüksek şiddet sınıfı 15,73 km² (%3,72) alan kaplamaktadır. Orta ve yüksek şiddet sınıfları birlikte değerlendirildiğinde, toplam 42,88 km²'lik (%10,14) alanın belirgin düzeyde yangından etkilendiği belirlenmiştir. Bu alanlar, dNDVI, dNBR ve RdNBR haritalarında yüksek değişim değerlerinin görüldüğü sahalarla büyük ölçüde örtüşmektedir. Bu dağılım, yangın etkisinin çalışma alanı genelinde homojen olmadığını ve orta-yüksek şiddette yanma alanlarının özellikle yangın sahasının iç kesimlerinde kümelendiğini göstermektedir (Şekil 9).

Tablo 5 dNBR tabanlı yanma şiddeti sınıflarının alansal dağılımı

Yanma Şiddeti Sınıfı	Alan (ha)	Alan (km²)	Oran (%)
Yanmamış / Çok Düşük Şiddet	36,820,25	368,20	87,04
Düşük Şiddet	1,193,80	11,94	2,82
Orta Şiddet	2,714,96	27,15	6,42
Yüksek Şiddet	1,573,30	15,73	3,72
Toplam	42,302,31	423,02	100,00

Şekil 9 dNBR indeksine göre yanma şiddetinin mekânsal dağılımı



Random Forest Sınıflandırma Sonuçları ve Değişken Önem Analizi

Random Forest sınıflandırmasının performansı bağımsız test verileriyle değerlendirilmiştir. Toplam 300 referans örneğinin (150 yanık, 150 yanmamış) 215'i eğitim, 85'i test amacıyla kullanılmış; 500 karar ağacı ile oluşturulan modelin genel doğruluğu %98,82, Kappa katsayısı ise 0,976 olarak hesaplanmıştır. Sınıf bazında, yanık alanlar için üretici doğruluğu %100,00, kullanıcı doğruluğu %97,56; yanmamış alanlar için ise üretici doğruluğu %97,78, kullanıcı doğruluğu %100,00 olarak belirlenmiştir. Bu sonuçlar, modelin yanık ve yanmamış alanları yüksek doğrulukla ayırt ettiğini göstermektedir (Tablo 6).

Tablo 6 Random Forest modeline ait doğruluk değerlendirme sonuçları

Ölçüt	Değer
Toplam örnek sayısı	300
Yanık örnek sayısı	150
Yanmamış örnek sayısı	150
Eğitim örnek sayısı	215
Test örnek sayısı	85
Karar ağacı sayısı	500
Genel doğruluk (%)	98,82
Kappa katsayısı	0,976
Yanık alanlar – Üretici doğruluğu (%)	100,00
Yanmamış alanlar – Üretici doğruluğu (%)	97,78
Yanık alanlar – Kullanıcı doğruluğu (%)	97,56
Yanmamış alanlar – Kullanıcı doğruluğu (%)	100,00

Random Forest algoritması kapsamında hesaplanan değişken önem değerleri, sınıflandırma performansına en fazla katkı sağlayan spektral indekslerin belirlenmesine olanak sağlamıştır (Tablo 7). Sonuçlara göre yangın sonrası NBR, 95,51 önem değeri ve %28,69 göreli önem oranı ile sınıflandırmaya en yüksek katkıyı sağlayan değişken olmuştur. Bu sonuç, yangın sonrası yakın kızılötesi (NIR) ve kısa dalga kızılötesi (SWIR) bantlarında meydana gelen spektral

değişimlerin yanık alanların belirlenmesinde belirleyici olduğunu göstermektedir.

Tablo 7 Random Forest algoritmasına göre spektral indekslerin değişken önem değerleri

Değişken	Önem Değeri	Göreli Önem (%)	Sıra
Yangın sonrası NBR	95,51	28,69	1
dNBR	69,45	20,87	2
RdNBR	65,66	19,73	3
dNDVI	50,39	15,14	4
Yangın sonrası NDVI	35,97	10,81	5
Yangın öncesi NBR	9,88	2,97	6
Yangın öncesi NDVI	5,98	1,80	7

Yangın sonrası NBR'yi dNBR (69,45; %20,87) ve RdNBR (65,66; %19,73) izlemiştir. Her iki indeks, yangın öncesi ve sonrası spektral değişimleri doğrudan yansıttığından yanık alanların belirlenmesinde yüksek ayırt edicilik göstermektedir. dNDVI ise 50,39 önem değeri ve %15,14 göreli önem oranıyla model performansına önemli katkı sağlamış, vejetasyondaki değişimleri etkili biçimde temsil etmiştir. Buna karşılık yangın sonrası NDVI (%10,81), yangın öncesi NBR (%2,97) ve yangın öncesi NDVI (%1,80) daha düşük önem değerlerine sahiptir. Bu durum, sınıflandırmada yangın sonrası spektral değişimlerin yangın öncesi koşullardan daha belirleyici olduğunu ortaya koymaktadır.

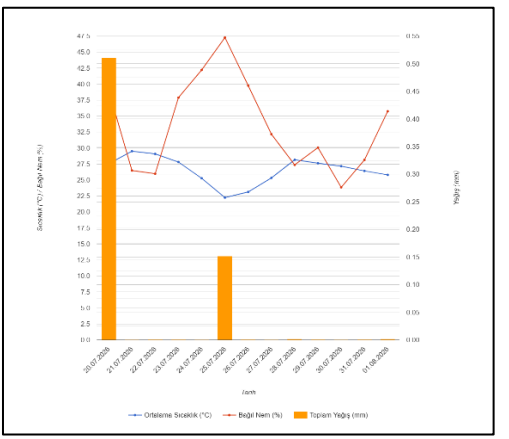
Değişken önem analizi, Random Forest modelinin ağırlıklı olarak yangın sonrası spektral özellikler ile yangın öncesi-sonrası farkını ortaya koyan değişim indekslerinden beslendiğini desteklemektedir. Bu bulgu, önceki bölümlerde dNDVI, dNBR ve RdNBR haritalarında belirlenen mekânsal değişim örüntüleri ile

uyumlu olup, özellikle yangın sonrası NBR, dNBR ve RdNBR indekslerinin Seydikemer orman yangınının etkilerinin belirlenmesinde en yüksek ayırt ediciliğe sahip değişkenler olduğunu ortaya koymaktadır.

Yangın Dönemindeki Meteorolojik Koşulların Değerlendirilmesi

Yangın öncesi ve yangın sürecindeki meteorolojik koşulların belirlenmesi amacıyla ERA5-Land günlük verileri kullanılarak araştırma sahasına ait sıcaklık, yağış, bağıl nem ve rüzgâr hızı incelenmiştir (Şekil 10). Bulgular, incelenen dönemde meteorolojik değişkenlerin zamansal olarak farklılık gösterdiğini ortaya koymaktadır.

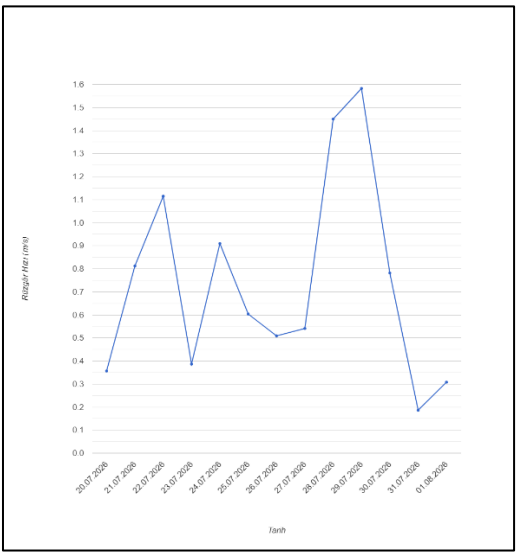
Şekil 10 ERA5-Land verilerine göre 20 Temmuz–01 Ağustos 2026 döneminde günlük ortalama sıcaklık, toplam yağış ve bağıl nem değerlerinin zamansal değişimi (UTC)



İncelenen dönemde günlük ortalama sıcaklık 22–30 °C arasında değişmiştir. Sıcaklık, dönemin başında 28–30 °C düzeyinde seyrederken 25–26 Temmuz'da 22–23 °C'ye gerilemiş, ardından yeniden yükselerek yangının başladığı günlerde 27–28 °C'ye ulaşmıştır. Bağıl nem ise %30–47 arasında değişmiş; en yüksek

değerler 24–26 Temmuz'da görülürken yangının meydana geldiği günlerde %33–35'e düşmüştür. Yağış miktarı oldukça sınırlı olup yalnızca 20 Temmuz'da yaklaşık 0,5 mm, 25 Temmuz'da ise yaklaşık 0,15 mm yağış kaydedilmiş, diğer günlerde belirgin yağış görülmemiştir. Rüzgâr hızı 0,2–1,6 m/s arasında değişmiş ve 28–29 Temmuz'da yaklaşık 1,5–1,6 m/s ile en yüksek seviyesine ulaşmıştır (Şekil 11). Bu bulgular, yangın başlangıcında yüksek sıcaklık, düşük bağıl nem, sınırlı yağış ve artan rüzgâr hızının birlikte etkili olduğunu işaret etmektedir. Ancak günlük ERA5-Land verileri yangının kısa süreli yayılım dinamiklerini yansıtmadığından, rüzgârın yangının yayılımına etkisi konusunda doğrudan nedensel bir değerlendirme yapılamamaktadır.

Şekil 11 ERA5-Land verilerine göre 20 Temmuz–01 Ağustos 2026 döneminde günlük ortalama rüzgâr hızının zamansal değişimi (UTC; m/s)



Tartışma

Bu çalışmada, 29 Temmuz 2026 tarihinde Seydikemer ilçesinde meydana gelen orman yangınının etkileri Sentinel-2 uydu görüntüleri, spektral indeksler (NDVI, NBR, dNDVI, dNBR ve RdNBR), Random Forest algoritması ve ERA5-Land meteorolojik verileri kullanılarak değerlendirilmiştir. Bulgular, yangının vejetasyon yapısında belirgin spektral değişimlere neden olduğunu ve çoklu veri kaynaklarının birlikte kullanımının yangın sonrası etkilerin değerlendirilmesinde etkili olduğunu göstermektedir.

NDVI ve NBR değerlerindeki azalma, yangın sonrası vejetasyon yapısı ve yüzey özelliklerinde meydana gelen değişimi ortaya koymaktadır. Bu bulgular, yangın sonrası klorofil ve biyokütle kaybına bağlı olarak NDVI'nın, yanmış alanların belirlenmesinde ise NBR'nin etkili olduğunu bildiren önceki çalışmalarla uyumludur (Escuin vd., 2008; Veraverbeke vd., 2010; Key & Benson, 2006; Miller & Thode, 2007). Ayrıca dNDVI, dNBR ve RdNBR sonuçları, yangın etkisinin çalışma alanında homojen dağılmadığını göstermektedir. Bununla birlikte, dNBR'nin doğrudan yanma şiddetini değil spektral değişimi temsil ettiği ve sonuçların topografya, vejetasyon yapısı, yakıt özellikleri ile görüntüleme zamanından etkilenebileceği dikkate alınmalıdır (Key & Benson, 2006; Parks vd., 2014).

Seydikemer orman yangını sonuçları, Coşkun vd. (2026) tarafından 2023 Çanakkale orman yangını için gerçekleştirilen çalışma ile karşılaştırıldığında farklılık göstermektedir. Çanakkale'de dNDVI %97,5 doğruluk ve 0,95 Kappa ile en başarılı indeks olurken, dNBR %84, Random Forest ise %92,6 doğruluk göstermiştir. Buna karşın Seydikemer'de Random Forest'ın %98,82 genel doğruluk ve 0,976 Kappa değerine ulaşması, yöntem performansının çalışma alanının vejetasyon yapısı, yangın özellikleri, kullanılan değişkenler ve referans örnekleme stratejisinden etkilenebileceğini göstermektedir.

Random Forest değişken önem analizi, NBR, dNBR ve RdNBR'nin sınıflandırmaya en yüksek katkıyı sağladığını ortaya koymuştur. Bu sonuç, SWIR bantlarına dayalı spektral değişimlerin yanık alanların belirlenmesinde önemli olduğunu ve Random Forest'ın yüksek doğruluklu yanık alan haritalaması sağlayabildiğini bildiren çalışmalarla uyumludur (Belgiu & Drăguţ, 2016; Gislason vd., 2006; Maxwell vd., 2018). Bununla birlikte, model performansının eğitim örneklerinin niteliği ve spektral ayrılabilirliğe bağlı olduğu göz önünde bulundurulmalı, farklı yangın alanlarında bağımsız doğrulama çalışmalarıyla desteklenmelidir.

Meteorolojik bulgular, yangın döneminde yüksek sıcaklık, sınırlı yağış, görece düşük bağıl nem ve artan rüzgâr hızının birlikte etkili olduğunu göstermektedir. Bu durum, yüksek sıcaklık, düşük nem ve rüzgârın orman yangınlarının gelişiminde belirleyici olduğunu bildiren çalışmalarla uyumludur (Jolly vd., 2015; Abatzoglou & Williams, 2016). Bununla birlikte, ERA5-Land verilerinin yeniden analiz ürünü olması nedeniyle meteorolojik bulguların yangının yerel yayılımını doğrudan açıklamak yerine yangın gelişimini destekleyen atmosferik koşullar olarak değerlendirilmesi daha uygundur.

Yangın rejimi, yangınların sıklığı, büyüklüğü, mevsimselliği ve şiddeti gibi özelliklerin yanı sıra iklim, vejetasyon ve insan faaliyetleri arasındaki etkileşimler çerçevesinde değerlendirilmektedir (Kelly vd., 2023; Ekberzade vd., 2025; Shen vd., 2025). Akdeniz ekosistemlerinde özellikle yaz kuraklığı, yüksek sıcaklıklar ve vejetasyonun nem içeriğindeki azalma, yangınların yayılımını ve ekosistemler üzerindeki etkilerini şekillendiren temel faktörler arasında yer almaktadır. Nitekim Akdeniz Havzası'na ilişkin araştırmalar, iklim değişikliğiyle ilişkili kuraklık ve yangına elverişli meteorolojik koşulların büyük yangınların oluşumu açısından önemini ortaya koymaktadır (Dupuy vd., 2020).

Bu çalışmada, 29 Temmuz 2026 tarihinde Seydikemer'de meydana gelen yangının başlangıç döneminde sıcaklığın 27–28 °C düzeyinde seyretmesi, yağışın oldukça sınırlı olması ve bağıl nemin %33–35'e gerilemesi, yangın gelişimini destekleyebilecek atmosferik koşullara işaret etmektedir. Bununla birlikte, ERA5-Land verilerinden elde edilen günlük ortalamalar yangının kısa süreli yayılım dinamiklerini ve yakıt nemindeki değişimleri doğrudan ortaya koymamaktadır. Bu nedenle söz konusu bulguların, yangının oluşumunu tek başına açıklayan etmenler olarak değil, yangın rejimini şekillendiren iklimsel bileşenlerle uyumlu koşullar olarak değerlendirilmesi gerekir.

Yangın rejiminin ekolojik açıdan değerlendirilmesi bakımından bu çalışmanın dNBR sonuçları da önem taşımaktadır. Orta ve yüksek yanma şiddeti sınıflarının toplam 42,88 km² alan kaplaması, yangın etkilerinin çalışma sahasında mekânsal olarak farklılaştığını göstermektedir. Bununla birlikte, dNBR sınıfları yangın rejiminin tamamını değil, belirli bir yangın olayının ardından ortaya çıkan spektral değişimlerin ve bunlara dayalı yanma şiddeti sınıflarının dağılımını temsil etmektedir. Kelly vd., (2023), yangın rejimindeki değişimlerin yalnızca tekil yangın olayları üzerinden değil, iklimsel ve beşerî etmenlerle birlikte uzun dönemli yangın örüntüleri çerçevesinde ele alınması gerektiğini vurgulamaktadır. Dolayısıyla Seydikemer örneği, Akdeniz orman ekosistemlerinde yangın sonrası etkilerin mekânsal olarak belirlenmesine katkı sağlamakla birlikte, yangın sıklığı, tekrarlanma aralığı veya rejim değişimi hakkında kesin sonuçlara ulaşmak için çok yıllı yangın kayıtları ve yangın geçmişi analizleriyle desteklenmelidir.

Sonuç ve Öneriler

Bu çalışmada, 29 Temmuz 2026 tarihinde Muğla ili Seydikemer ilçesinde meydana gelen orman yangınının etkileri Sentinel-2 uydu görüntüleri, spektral indeksler (NDVI, NBR,

dNDVI, dNBR ve RdNBR), Random Forest algoritması ve ERA5-Land meteorolojik verileri kullanılarak değerlendirilmiştir. Bulgular, uzaktan algılama ve makine öğrenmesi yöntemlerinin yangın sonrası spektral değişimlerin belirlenmesi ve etkilenen alanların sınıflandırılmasında kullanılabilirliğini ortaya koymuştur.

dNBR tabanlı sınıflandırmaya göre çalışma alanının %87,04'ü yanmamış veya çok düşük şiddette etkilenmiş, %12,96'sı ise düşük, orta ve yüksek yanma şiddeti sınıflarında yer almıştır. Random Forest algoritmasının %98,82 genel doğruluk ve 0,976 Kappa katsayısı elde etmesi, kullanılan değişkenlerin sınıflandırma performansına katkısını göstermektedir. Değişken önem analizi, özellikle yangın sonrası NBR, dNBR ve RdNBR indekslerinin modelde öne çıktığını ortaya koymuştur. ERA5-Land verileri ise yangın döneminde sıcaklık, yağış, bağıl nem ve rüzgâr koşullarının zamansal değişimini değerlendirmeye olanak sağlamıştır. Bununla birlikte, meteorolojik koşulların yangının yayılımına etkisi yorumlanırken verilerin zamansal çözünürlüğü ve yangın davranışını belirleyen diğer etmenler göz önünde bulundurulmalıdır.

Çalışmanın uygulamaya dönük sonuçları doğrultusunda, orta ve yüksek yanma şiddeti sınıflarında belirlenen alanların arazi gözlemleriyle doğrulanması ve vejetasyon kaybı, ağaçların canlılık durumu, toprak örtüsü ve doğal gençleşme potansiyeli bakımından incelenmesi önerilmektedir. Özellikle eğimli arazilerde ve yüzey akışına duyarlı bölgelerde erozyon riskinin değerlendirilmesi, restorasyon önceliklerinin belirlenmesine katkı sağlayacaktır. Müdahale ve rehabilitasyon kararları yalnızca spektral indeks sonuçlarına dayandırılmamalı; doğal yenilenme kapasitesi ve alanın ekolojik özellikleri dikkate alınarak planlanmalıdır.

Yangının tarım alanından ormanlık alana yayılmış olması, orman-kırsal alan arayüzünde yangın önleme uygulamalarının önemini de ortaya koymaktadır. Anız ve bahçe atıklarının yakılmasının önlenmesi, kıvılcım oluşturabilecek tarımsal

ekipmanların kontrollü kullanılması ve yangın riski yüksek dönemlerde yerel halkın bilgilendirilmesi bu kapsamda değerlendirilebilir. Ayrıca, yangın sonrası vejetasyon değişiminin farklı tarihlere ait uydu görüntüleriyle izlenmesi ve elde edilen sonuçların arazi verileriyle desteklenmesi, ekosistemin iyileşme sürecinin değerlendirilmesini sağlayacaktır (Şekil 12-13).

Şekil 12 Seydikemer orman yangını sonrasında etkilenen sahanın görünümü.



Şekil 13 Seydikemer orman yangını sonrasında yanmış orman alanlarının genel görünümü



Gelecek çalışmalarda farklı yangın alanlarının karşılaştırılması, bağımsız doğrulama verilerinin kullanılması ve alternatif makine öğrenmesi yöntemlerinin değerlendirilmesi, geliştirilen yaklaşımın farklı ekolojik koşullardaki performansının daha kapsamlı biçimde ortaya konulmasına yardımcı olacaktır. Bu bütünleşik yaklaşım, yangın sonrası hasar değerlendirmesinin yanı sıra restorasyon önceliklerinin belirlenmesi ve sürdürülebilir orman yönetimi stratejilerinin geliştirilmesi için de destekleyici bir araç niteliği taşımaktadır.

Kaynakça

Abatzoglou, J. T., & Williams, A. P. (2016). Impact of anthropogenic climate change on wildfire across western US forests. *Proceedings of the National Academy of Sciences*, 113(42), 11770–11775. https://doi.org/10.1073/pnas.1607171113

Belgiu, M., & Drăguț, L. (2016). Random forest in remote sensing: A review of applications and future directions. *ISPRS Journal of Photogrammetry and Remote Sensing*, 114, 24–31. https://doi.org/10.1016/j.isprsjprs.2016.01.011

Bilgili, E., Sağlam, B., Küçük, Ö., & Durmaz, B. D. (2010). Fire behavior in Mediterranean forest ecosystems. *African Journal of Biotechnology*, 9(29), 4389–4394.

Bowman, D. M. J. S., Balch, J. K., Artaxo, P., Bond, W. J., Carlson, J. M., Cochrane, M. A., D'Antonio, C. M., DeFries, R. S., Doyle, J. C., Harrison, S. P., Johnston, F. H., Keeley, J. E., Krawchuk, M. A., Kull, C. A., Marston, J. B., Moritz, M. A., Prentice, I. C., Roos, C. I., Scott, A. C., Swetnam, T. W., ... van der Werf, G. R. (2009). *Fire in the Earth system. Science*, 324(5926), 481–484. https://doi.org/10.1126/science.1163886

Bozyiğit, R. (2020). Seydikemer ilçesi (Muğla) topraklarının özellikleri ve kullanımı üzerine bir değerlendirme. *Avrupa Bilim ve*

Teknoloji Dergisi, 18, 695–706. https://doi.org/10.31590/ejosat.702654

Breiman, L. (2001). Random forests. Machine Learning, 45(1), 5–32. https://doi.org/10.1023/A:1010933404324

Chuvieco, E., Aguado, I., Jurdao, S., Pettinari, M. L., Yebra, M., Salas, J., Hantson, S., De La Riva, J., Ibarra, P., Rodrigues, M., Echeverría, M., Azqueta, D., Román, M. V., Bastarrika, A., Martínez, S., Recondo, C., Zapico, E., & Martínez-Vega, F. J. (2014). Integrating geospatial information into fire risk assessment. *International Journal of Wildland Fire*, 23(5), 606–619. https://doi.org/10.1071/WF12052

Coşkun, S., Minaz, D., & Coşkun, M. (2026). Comparative evaluation of spectral indices and random forest for burned area mapping: A case study of the 2023 Çanakkale wildfire (Türkiye). *International Journal of Disaster Risk Reduction*, 143,106327. https://doi.org/10.1016/j.ijdrr.2026.106327

Drusch, M., Del Bello, U., Carlier, S., Colin, O., Fernandez, V., Gascon, F., Hoersch, B., Isola, C., Laberinti, P., Martimort, P., Meygret, A., Spoto, F., Sy, O., Marchese, F., & Bargellini, P. L. (2012). Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, 120, 25–36.

Dupuy, J.-L., Pimont, F., Ruffault, J., Fargeon, H., Martin-StPaul, N., & Rigolot, E. (2020). Climate change impact on future wildfire danger and activity in southern Europe: A review. *Annals of Forest Science*, 77, 35. https://doi.org/10.1007/s13595-020-00933-5

Ekberzade, B., Görüm, T., Karabacak, F., Akay, S. S., & Şen, Ö. L. (2025). Up in flames: The human factor behind a megafire in Mediterranean Türkiye. *npj Natural Hazards*, 2, 65.

Escuin, S., Navarro, R., & Fernández, P. (2008). Fire severity assessment by using NBR (Normalized Burn Ratio) in the

Mediterranean area. *International Journal of Remote Sensing*, 29(4), 1053–1073. https://doi.org/10.1080/01431160701281072

Gislason, P. O., Benediktsson, J. A., & Sveinsson, J. R. (2006). Random forests for land cover classification. *Pattern Recognition Letters*, 27(4), 294–300. https://doi.org/10.1016/j.patrec.2005.08.011

Gorelick, N., Hancher, M., Dixon, M., Ilyushchenko, S., Thau, D., & Moore, R. (2017). Google Earth Engine: Planetary-scale geospatial analysis for everyone. *Remote Sensing of Environment*, 202, 18–27. https://doi.org/10.1016/j.rse.2017.06.031

Jolly, W. M., Cochrane, M. A., Freeborn, P. H., Holden, Z. A., Brown, T. J., Williamson, G. J., & Bowman, D. M. J. S. (2015). Climate-induced variations in global wildfire danger from 1979 to 2013.*Nature Communications*,6,7537. https://doi.org/10.1038/ncomms8537

Keeley, J. E., Bond, W. J., Bradstock, R. A., Pausas, J. G., & Rundel, P. W. (2012). Fire in Mediterranean ecosystems: *Ecology, evolution and management*. Cambridge University Press.

Kelly, L. T., Fletcher, M.-S., Oliveras Menor, I., Pellegrini, A. F., Plumanns-Pouton, E. S., Pons, P., … Bowman, D. M. (2023). Understanding fire regimes for a better Anthropocene. *Annual Review of Environment and Resources*, 48(1), 207–235.

Key, C. H., & Benson, N. C. (2006). Landscape assessment: Ground measure of severity, the Composite Burn Index, and remote sensing of severity, the Normalized Burn Ratio. In D. C. Lutes et al. (Eds.), FIREMON: *Fire effects monitoring and inventory system* (General Technical Report RMRS-GTR-164-CD, pp. LA-1–LA-55). U.S. Department of Agriculture, Forest Service, Rocky Mountain Research Station.

Madiba, S., Boshoff, D., & Dlamini, M. (2026). Wildfire burn severity in the Mediterranean biome: A systematic review. *Discover Sustainability*, 7, 251. https://doi.org/10.1007/s43621-026-02588-0

Maxwell, A. E., Warner, T. A., & Fang, F. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, 39(9), 2784–2817. https://doi.org/10.1080/01431161.2018.1433343

Miller, J. D., & Thode, A. E. (2007). Quantifying burn severity in a heterogeneous landscape with a relative version of the delta Normalized Burn Ratio (dNBR). *Remote Sensing of Environment*, 109(1), 66–80. https://doi.org/10.1016/j.rse.2006.12.006

Muñoz-Sabater, J., Dutra, E., Agustí-Panareda, A., Albergel, C., Arduini, G., Balsamo, G., Boussetta, S., et al. (2021). ERA5-Land: A state-of-the-art global reanalysis dataset for land applications. *Earth System Science Data*, 13(9), 4349–4383. https://doi.org/10.5194/essd-13-4349-2021

Parks, S. A., Dillon, G. K., & Miller, C. (2014). A new metric for quantifying burn severity: The relativized burn ratio. *Remote Sensing*, 6(3), 1827–1844. https://doi.org/10.3390/rs6031827

Rouse, J. W., Haas, R. H., Schell, J. A., & Deering, D. W. (1974). Monitoring vegetation systems in the Great Plains with ERTS. *In Proceedings of the Third Earth Resources Technology Satellite-1 Symposium (NASA SP-351, Vol. 1, pp. 309–317)*. National Aeronautics and Space Administration.

Rovithakis, A., Grillakis, M. G., Seiradakis, K. D., Giannakopoulos, C., Karali, A., Field, R. D., Lazaridis, M., & Voulgarakis, A. (2022). Future climate change impact on wildfire

danger over the Mediterranean: The case of Greece. *Environmental Research Letters*, 17(4), 045022. https://doi.org/10.1088/1748-9326/ac5f94

Sağlam, B., Bilgili, E., Küçük, Ö., & Durmaz, B. D. (2008). Fire behavior in Mediterranean shrub species (Maquis). *African Journal of Biotechnology*, 7(22), 4122–4129. https://doi.org/10.5897/AJB08.782

Shen, Z., Giljohann, K., Liu, Z., Pausas, J., & Rogers, B. (2025). Novel wildfire regimes under climate change and human activity: Patterns, driving mechanisms and ecological impacts. Philosophical Transactions of the Royal Society B: *Biological Sciences*, 380(1924), 20230446. https://doi.org/10.1098/rstb.2023.0446

Veraverbeke, S., Lhermitte, S., Verstraeten, W. W., & Goossens, R. (2010). The temporal dimension of differenced Normalized Burn Ratio (dNBR) fire/burn severity studies: The case of the large 2007 Peloponnese wildfires in Greece. *Remote Sensing of Environment*, 114(11), 2548–2563. https://doi.org/10.1016/j.rse.2010.05.029

İnternet Kaynakları

Muğla Valiliği. (2026). Genel emir 2026/1: Orman yangınlarının önlenmesi hakkında karar. https://www.mugla.gov.tr/genel-emir-20261-orman-yanginlarinin-onlenmesi-hakkinda-karar

Resmî Gazete. (2012, 6 Aralık). [6 Aralık 2012 tarihli ve 28489 sayılı Resmî Gazete'de yayımlanan düzenleme]. https://www.resmigazete.gov.tr/eskiler/2012/12/20121206-1.htm

T.C. Çevre, Şehircilik ve İklim Değişikliği Bakanlığı, Meteoroloji Genel Müdürlüğü Meteoroloji Genel Müdürlüğü. (t.y.). Resmî iklim istatistikleri: Muğla. Erişim tarihi 8 Ağustos 2026,

https://www.mgm.gov.tr/veridegerlendirme/il-ve-ilceler-istatistik.aspx?k=H&m=MUGLA

Teşekkür

Bu kitap bölümünün hazırlanması sürecinde, çalışma sahasına ilişkin bilgi ve fotoğrafları paylaşarak çalışmaya değerli katkılar sunan Orman Mühendisi Sayın Murat CANAVARCI'ya teşekkürlerimi sunarım.

BÖLÜM 3

İÇ ANADOLU'DA KARA–ATMOSFER ETKİLEŞİMİ: TOPRAK NEMİ VE YAZ SICAKLIĞI İLİŞKİSİ

FERHAT KESERCİ[1]

Giriş

İklim değişikliğiyle birlikte yaz sıcaklıklarında gözlenen artış, bölgesel ölçekte farklı özellikler göstermekte ve sıcaklıkların yıllar arasındaki değişkenliği üzerinde çeşitli süreçler etkili olmaktadır. Özellikle nemli ve kurak iklimler arasındaki geçiş bölgelerinde, önceki mevsimlerin hidrolojik koşulları yaz aylarındaki sıcaklık özelliklerini etkileyebilmektedir. Avrupa'da gerçekleştirilen iklim modeli deneyleri, kara-atmosfer etkileşimlerinin yaz sıcaklıklarındaki değişkenlik üzerinde önemli bir rol oynayabildiğini ortaya koymuştur (Seneviratne et al., 2006). Akdeniz geçiş iklimlerinde yapılan araştırmalar ise başlangıçtaki toprak suyu koşullarının sonraki aylardaki sıcaklıklar üzerinde etkili olabildiğini göstermektedir (Materia et al., 2022). Bu bulgular, yaz sıcaklıklarının oluşumunda yalnızca mevcut atmosferik koşulların değil, önceki mevsimlerden aktarılan yüzey özelliklerinin de dikkate alınması gerektiğine işaret etmektedir.

Yaz sıcaklıklarının yıllar arasındaki değişiminde büyük ölçekli atmosferik dolaşım koşullarının yanı sıra kara yüzeyindeki su ve enerji dengesi de önemli bir rol oynamaktadır. Yüzeydeki net ışınımın gizli ve duyulur ısı akıları arasındaki dağılımı, büyük ölçüde toprakta bulunan kullanılabilir su miktarına bağlıdır. Toprak neminin yeterli olduğu koşullarda yüzeye ulaşan enerjinin önemli bir bölümü buharlaşma ve terleme yoluyla tüketilirken nemin azalmasıyla birlikte duyulur ısı akısının payı artmakta ve yüzeye yakın hava sıcaklıkları yükselmektedir. Toprak nemi ile hava sıcaklığı arasındaki bu ilişki, buharlaşmanın esas olarak mevcut enerjiyle sınırlandığı nemli bölgelerde görece zayıftır. Buna karşılık, su mevcudiyetinin buharlaşmayı sınırlamaya başladığı yarı nemli ve yarı kurak geçiş bölgelerinde çok daha belirgin hâle gelmektedir (Seneviratne et al., 2010).

Toprak neminin atmosferik koşullara verdiği tepki yalnızca eş zamanlı süreçlerle sınırlı değildir. Yağış ve buharlaşma koşullarına bağlı olarak ortaya çıkan toprak nemi anomalileri, belirli bir süre varlığını koruyabilmekte ve sonraki aylardaki yüzey enerji dengesini etkileyebilmektedir. Toprak nemi belleği olarak tanımlanan bu özellik, atmosferik koşulların mevsimsel değişimine ve buharlaşma ile yüzey akışının toprak nemine verdiği tepkiye bağlı olarak farklı bölgelerde farklı sürelerde etkili olmaktadır. Bu nedenle toprak nemi, mevsimsel iklim tahminlerinde dikkate alınması gereken önemli bir öngörülebilirlik kaynağıdır (Koster & Suarez, 2001). Nitekim Avrupa'da 2003 yılında yaşanan aşırı sıcak yaz koşullarını ele alan bölgesel iklim modeli deneyleri, ilkbahardaki toprak nemi miktarının yaz mevsiminde ortaya çıkan sıcaklık anomalilerinin büyüklüğünü önemli ölçüde etkileyebildiğini göstermiştir (Fischer et al., 2007).

Toprak neminin yaz sıcaklıkları üzerindeki etkisi, bölgesel iklim özelliklerine bağlı olarak önemli farklılıklar göstermektedir. Güneydoğu Avrupa'daki meteoroloji istasyonlarının kayıtları

üzerinde yapılan analizlerde, önceki dönemlerde yaşanan yağış eksikliği ile aşırı yüksek sıcaklıklar arasında güçlü bir ilişki belirlenirken aynı ilişkinin daha nemli iklim koşullarına sahip Orta Avrupa'da belirgin olmadığı görülmüştür (Hirschi et al., 2011). Benzer şekilde, küresel ölçekte gerçekleştirilen araştırmalar, yağışların normalin altında gerçekleştiği dönemleri izleyen aylarda aşırı sıcak günlerin görülme olasılığının birçok bölgede arttığını ortaya koymuştur (Mueller & Seneviratne, 2012). Avrupa genelinde yaz mevsiminin en yüksek sıcaklıkları ile toprak nemi arasındaki ilişkinin mekânsal dağılımını inceleyen Whan et al. (2015) ise söz konusu ilişkinin özellikle Güney-Orta Avrupa ile Güneydoğu Avrupa'da güçlendiğini belirlemiştir.

Bununla birlikte, yaz mevsiminde görülen yüksek sıcaklıkların yalnızca toprak nemi koşullarıyla açıklanması mümkün değildir. Toprak neminin sıcaklık üzerindeki etkisi, atmosferik dolaşım özelliklerine ve bunların sürekliliğine bağlı olarak değişebilmektedir. Quesada et al. (2012), Güney Avrupa'da yağışlı geçen kış ve ilkbahar mevsimlerinin yaz aylarındaki sıcak günlerin sıklığını azalttığını, buna karşılık kurak dönemleri izleyen yazlarda sıcak gün sayısının her zaman artmadığını belirlemiştir. Araştırmacılar, bu farklılığın büyük ölçüde hâkim atmosferik dolaşım koşullarıyla ilişkili olduğunu göstermiştir. Avrupa'da 2003 ve Rusya'da 2010 yıllarında meydana gelen sıcak hava dalgalarını inceleyen Miralles et al. (2014), uzun süre devam eden atmosferik basınç düzenleri altında toprak neminin azalması ve atmosferik sınır tabakasında ısının birikmesinin aşırı sıcaklıkların şiddetlenmesinde birlikte rol oynadığını ortaya koymuştur. Kara yüzeyi ile atmosfer arasındaki geri besleme mekanizmalarını değerlendiren Miralles et al. (2019) da toprak neminin sıcaklık üzerindeki etkilerinin atmosferik dolaşımın etkileriyle birlikte ele alınmasının önemini vurgulamaktadır. Dolayısıyla ilkbahardaki toprak nemi koşulları ile yaz sıcaklıkları arasında belirlenen ilişkilerin değerlendirilmesinde,

atmosferik dolaşımdan kaynaklanan sıcaklık değişimlerinin ayrıca dikkate alınması gerekmektedir.

Türkiye'de sıcaklık ve yağış koşullarının uzun dönemli değişimini inceleyen çalışmalar, mevsimsel ve bölgesel ölçekte farklılaşan eğilimlerin bulunduğunu göstermektedir. Türkeş et al. (2002), 1929–1999 dönemini kapsayan meteorolojik gözlemlerden hareketle en belirgin ısınma eğiliminin minimum sıcaklıklarda, özellikle de yaz gecelerinde ortaya çıktığını belirlemiştir. Bununla birlikte, aynı dönemde ortalama yaz sıcaklıklarının Türkiye'nin kuzeyinde ve karasal özellik taşıyan iç kesimlerinde azalma eğiliminde olduğu gözlemlenmiştir. Daha güncel bir dönemi kapsayan Bayer-Altın (2023) ise 1960–2021 yılları arasında İç Anadolu'daki meteoroloji istasyonlarında kaydedilen sıcaklık değişimlerini inceleyerek yaz mevsimindeki sıcaklık artışlarının yıllık ısınma eğilimine önemli katkı sağladığını ortaya koymuştur. Türkiye'deki yağışların uzun dönemli değişimini inceleyen Unal et al. (2012), 1961–2008 döneminde Anadolu'nun büyük bölümünde yıllık yağışlarda azalma eğiliminin baskın olduğunu belirlemiştir. Özellikle karasal iklim özelliklerinin belirgin olduğu iç kesimlerin kısa zaman ölçeklerinde gelişen şiddetli kuraklıklara ve tarımsal kuraklık koşullarına karşı daha duyarlı olduğu ifade edilmektedir (Sönmez et al., 2005). Diğer taraftan, 2007 yazında yaşanan aşırı sıcaklıklar gibi dikkat çekici olayların atmosferik bloklanma koşulları ve sıcak hava dalgalarıyla ilişkili olduğu gösterilmiştir (Demirtaş, 2018). Türkiye'de sıcaklık, yağış ve kuraklık koşullarının uzun dönemli değişimine ilişkin çok sayıda araştırma bulunmasına karşın, İç Anadolu'da ilkbahar toprak nemi ile yaz sıcaklıkları arasındaki gecikmeli ilişkiyi, atmosferik dolaşımın etkisini de dikkate alarak inceleyen çalışmalar sınırlıdır. Bu kapsamda, ilkbahar toprak neminin farklı derinliklerdeki değişimi ile yaz sıcaklıkları arasındaki ilişkinin mekânsal ve zamansal özelliklerinin

belirlenmesi, bölgedeki sıcaklık değişkenliğinin ve kara-atmosfer etkileşimlerinin daha iyi anlaşılmasına katkı sağlayacaktır.

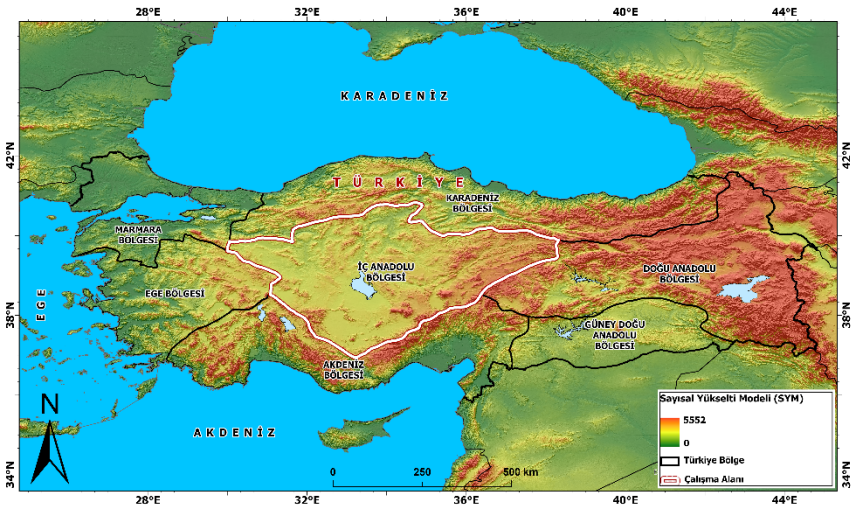
İç Anadolu, toprak nemi ile yaz sıcaklığı arasındaki ilişkinin incelenmesi için Türkiye'de en uygun alanlardan biridir. Toroslar ve Kuzey Anadolu Dağları ile çevrili, ortalama yükseltisi 1187 m olan bu plato, denizel etkilerden büyük ölçüde yalıtılmıştır. Yıllık yağışın yaklaşık %37'si ilkbaharda düşerken yaz yağışları ise %11'de kalmaktadır. Kış ve ilkbaharda toprakta biriken su yaz boyunca azalır ve buharlaşma her yıl yeniden toprak nemine bağımlı hale gelir. Bu yapı bölgeyi, toprak nemi ile sıcaklık arasındaki eşleşmenin en güçlü olduğu nemli ve kurak rejimler arasındaki geçiş iklimine yerleştirir (Seneviratne et al., 2010). Benzer bir geçiş iklimine sahip güneydoğu Avrupa'da önceki yağış açığı ile ekstrem sıcaklıklar arasında güçlü bir bağ bulunmuş, aynı bağ daha nemli bir yapı gösteren Orta Avrupa'da görülmemiştir (Hirschi et al., 2011). Çalışma alanı olarak İç Anadolu Bölgesi'nin seçilmesinin ikinci nedeni, iklimsel değişimin burada belirgin biçimde hissedilmesidir. İç Anadolu'da yaz sıcaklıklarındaki artış yıllık ısınmayı büyütmekte (Bayer-Altın, 2023), Anadolu'nun büyük bölümünde yağışta azalma eğilimleri görülmekte (Unal et al., 2012) ve iç kesimler kısa zaman ölçeklerindeki şiddetli kuraklıklara ve tarımsal kuraklığa daha açık hale gelmektedir (Sönmez et al., 2005). Tahıl üretimi ve sulu tarım açısından ülkenin en önemli alanlarından birini oluşturan bu bölgede ilkbahar toprak neminin yaz sıcaklığıyla ilişkisini ortaya koymak, hem kara-atmosfer etkileşiminin işleyişini anlamak hem de mevsimsel tahmin ve su yönetimi için önem taşımaktadır.

Bu bölümde 1981–2024 dönemi için ERA5-Land verileriyle önce iki değişkenin uzun dönemli eğilimleri belirlenmiş, ardından eğilimden arındırılmış serilerde ilişkinin hangi toprak katmanında ve hangi aylarda güçlendiği, bölge içinde nasıl dağıldığı ve yaz dolaşımı denetlendiğinde varlığını koruyup korumadığı sınanmıştır.

Çalışma Alanı

İç Anadolu Bölgesi, 30,0°–38,3° doğu boylamları ile 36,9°–40,8° kuzey enlemleri arasında uzanmakta olup çalışmada kullanılan coğrafi sınır verisine göre yaklaşık 158 bin km²'lik bir alanı kapsamaktadır (Şekil 1). Kuzeyde Kuzey Anadolu Dağları, güneyde ise Toros Dağları ile çevrelenen bölge, geniş platoların ve düzlüklerin hâkim olduğu yüksek bir iç havza görünümündedir. Kıyılardan gelen nemli hava kütlelerinin dağlık alanlarda orografik yağış bırakması, denizel etkilerin iç kesimlere ulaşmasını sınırlandırmakta ve bölgenin karasal iklim özelliklerini güçlendirmektedir. Bölge genelinde yükselti ve yer şekilleri bakımından belirgin farklılıklar bulunmakla birlikte, geniş alanlar 1000 metrenin üzerinde yer almaktadır. ERA5-Land veri setinde 1642 grid hücresiyle temsil edilen çalışma alanının ortalama yükseltisi 1187 m'dir. Grid hücrelerinin yaklaşık %59'u 1000–1500 m, %25'i 500–1000 m ve %15'i 1500–2000 m yükselti aralığında bulunmaktadır. Tuz Gölü kapalı havzası ve Konya Ovası, bölgenin geniş ve nispeten alçak düzlüklerini oluştururken çevredeki yüksek plato ve dağlık alanlar topoğrafik çeşitliliği artırmaktadır. Yükselti, yer şekilleri ve denizel etkilere uzaklığın birlikte şekillendirdiği bu coğrafi yapı, bölge genelinde sıcaklık, yağış ve toprak nemi koşullarının mekânsal farklılaşmasında önemli bir rol oynamaktadır.

Şekil 1. İç Anadolu Bölgesi'nin konumu ve yükselti dağılımı.



1981–2024 döneminde İç Anadolu Bölgesi'nin yıllık ortalama hava sıcaklığı 10,5 °C, yıllık toplam yağış miktarı ise 451 mm'dir. Aylık ortalama sıcaklıklar Ocak ayında −1,2 °C'ye kadar düşerken Temmuz ve Ağustos aylarında sırasıyla 22,0 ve 22,2 °C'ye ulaşmaktadır. Yağışların yıl içindeki dağılımı belirgin bir mevsimsellik göstermektedir. Yıllık toplam yağışın yaklaşık %37'si ilkbahar aylarında gerçekleşirken yaz mevsiminin payı yalnızca %11 düzeyindedir. Aylık yağış miktarı Mayıs ayında 56 mm ile en yüksek değerine ulaşmakta, Ağustos ayında ise 7,5 mm'ye kadar gerilemektedir. Yağış ve sıcaklığın mevsimsel değişimi, toprak neminin yıl içindeki seyrine de yansımaktadır. Yüzeye yakın 0–7 cm derinlikteki toprak nemi, Mart ayında ortalama 0,340 $m^3\ m^{-3}$ ile en yüksek düzeyine ulaşırken yaz boyunca azalarak Ağustos ayında 0,127 $m^3\ m^{-3}$'e düşmektedir. Daha derindeki 28–100 cm katmanında ise en yüksek toprak nemi Nisan ayında, en düşük değer Ekim ayında görülmektedir. Bu durum, derin toprak katmanlarının yüzeye yakın katmanlardaki mevsimsel değişimi yaklaşık bir ila iki aylık gecikmeyle izlediğini göstermektedir. Kış ve ilkbahar aylarında

toprakta depolanan suyun yaz boyunca giderek azalması, özellikle yağışların sınırlı olduğu sıcak dönemlerde buharlaşma ve terleme süreçlerinin toprakta kalan kullanılabilir su miktarına daha fazla bağımlı hâle gelmesine neden olmaktadır.

Veri ve Yöntem

Çalışmada temel veri kaynağı olarak ERA5-Land aylık yeniden analiz veri seti kullanılmıştır (Muñoz-Sabater et al., 2021). Yaklaşık 0,1° mekânsal çözünürlüğe sahip ERA5-Land, ERA5 atmosferik yeniden analizinin (Hersbach et al., 2020) yüzeye yakın meteorolojik değişkenleriyle beslenen ve atmosferik modelden bağımsız olarak çalıştırılan bir kara yüzeyi modeline dayanmaktadır. ERA5'ten alınan sıcaklık, nem ve basınç alanları, iki veri setinin ızgara hücreleri arasındaki yükselti farkları dikkate alınarak düzeltilmektedir. Bununla birlikte ERA5-Land, gözlem verilerinin doğrudan özümlendiği bir yeniden analiz sistemi olmayıp atmosferik koşulların kara yüzeyi üzerindeki etkilerini modelleyen bir veri setidir (Muñoz-Sabater et al., 2021). Çalışma kapsamında 35°–43° kuzey enlemleri ile 25°–45° doğu boylamları arasında kalan alan için 2 m hava sıcaklığı, toplam yağış ve üç farklı toprak derinliğine (0–7, 7–28 ve 28–100 cm) ait hacimsel toprak su içeriği verileri elde edilmiştir. ERA5-Land aylık ürününde yağış gibi birikimli değişkenler, günlük birikimlerin aylık ortalaması biçiminde sunulduğundan yağış değerleri 1000 ile ilgili ayın gün sayısı çarpılarak milimetre cinsinden aylık toplam yağış miktarına dönüştürülmüştür (ECMWF, 2026). Büyük ölçekli atmosferik dolaşım koşullarını temsil etmek amacıyla ERA5 veri setinin 0,25° çözünürlüklü 500 hPa jeopotansiyel (Z500) alanından yararlanılmıştır. Jeopotansiyel değerleri, standart yerçekimi ivmesine bölünerek jeopotansiyel metre (gpm) cinsine dönüştürülmüştür.

Bölgesel ortalamaların hesaplanmasında, ızgara hücrelerinin enleme bağlı olarak değişen yüzey alanlarının sonuçlar üzerindeki etkisini

azaltmak amacıyla kosinüs enlem ağırlıklandırması uygulanmıştır. Mevsimsel değerlendirmelerde ilkbahar dönemi Mart, Nisan ve Mayıs (MAM), yaz dönemi ise Haziran, Temmuz ve Ağustos (JJA) aylarını kapsamaktadır. Sıcaklık ve toprak nemi için mevsimlik ortalama değerler hesaplanırken yağış değişkeninde ilgili üç ayın toplamı esas alınmıştır. Toprak neminin farklı derinliklerdeki değişimini birlikte değerlendirebilmek amacıyla, bitki köklerinin önemli bir bölümünün bulunduğu 0–100 cm derinliğindeki toprak profili tek bir değişkenle temsil edilmiştir. Bunun için 0–7, 7–28 ve 28–100 cm katmanlarına ait hacimsel toprak nemi değerleri, her katmanın kalınlığı dikkate alınarak ağırlıklandırılmış ve 0–100 cm toprak profiline ait ortalama nem içeriği aşağıdaki eşitlikle hesaplanmıştır:

$$\theta_{kb} = \frac{7\theta_1 + 21\theta_2 + 72\theta_3}{100} \quad (1)$$

Burada θ_1, θ_2 ve θ_3 sırasıyla 0–7, 7–28 ve 28–100 cm derinliklerindeki toprak katmanlarının hacimsel su içeriğini ($m^3\ m^{-3}$) ifade etmektedir. Büyük ölçekli atmosferik dolaşım koşullarını değerlendirmek amacıyla İç Anadolu Bölgesi'ni kapsayan 37°–41° kuzey enlemleri ile 30°–38,5° doğu boylamları arasındaki alanda, yaz aylarına (JJA) ait 500 hPa jeopotansiyel yükseklik (Z500) ortalamaları hesaplanmış ve dolaşım göstergesi olarak kullanılmıştır. Bununla birlikte, troposferdeki sıcaklık artışı atmosferik dolaşım koşullarındaki değişimlerden bağımsız olarak da jeopotansiyel yükseklikler artmasına neden olabilmektedir. Bu nedenle Z500 serisinde belirlenen uzun dönemli eğilimler doğrudan atmosferik dolaşımın dinamik yapısındaki değişimlerin göstergesi olarak değerlendirilmemiştir.

İklim değişkenlerinin uzun dönemli eğilimleri, eğilim büyüklüğünün belirlenmesinde Sen (1968) eğim kestiricisi, istatistiksel anlamlılığın değerlendirilmesinde ise Mann-Kendall testi (Mann, 1945) kullanılarak incelenmiştir. Zaman serilerinde

bulunabilecek seri bağımlılığın Mann-Kendall testinin varyansını ve dolayısıyla anlamlılık düzeyini etkilemesini önlemek amacıyla Hamed & Rao (1998) tarafından önerilen varyans düzeltmesi uygulanmıştır. Değişkenler arasındaki ilişkiler incelenmeden önce bölgesel ortalama serilerin ve her bir ızgara hücresine ait zaman serilerinin doğrusal eğilimleri giderilmiştir. Bu işlem, uzun dönemli iklim değişimlerinden kaynaklanan ortak eğilimlerin korelasyon katsayıları üzerindeki etkisini azaltmak amacıyla gerçekleştirilmiştir.

Özellikle sıcaklıkların artması ve toprak neminin azalması yönündeki eş zamanlı eğilimler, iki değişkenin yıllar arasındaki değişimleri arasında güçlü bir ilişki bulunmasa bile negatif korelasyon katsayılarının ortaya çıkmasına neden olabilmektedir. Nitekim ilkbahar kök bölgesi toprak nemi ile yaz sıcaklığı arasındaki Pearson korelasyon katsayısı, ham zaman serilerinde −0,56 olarak hesaplanırken doğrusal eğilimlerin giderilmesinin ardından −0,40'a düşmüştür. Pearson korelasyon katsayılarının istatistiksel anlamlılığı değerlendirilirken zaman serilerindeki özbağıntı da dikkate alınmıştır. Bu amaçla, her iki serinin birinci dereceden özbağıntı katsayıları (r_1 ve r_2) kullanılarak Bretherton et al. (1999) tarafından önerilen etkin örneklem büyüklüğü hesaplanmıştır:

$$n_{eff} = n\frac{1-r_1 r_2}{1+r_1 r_2} \quad (2)$$

Doğrusal eğilimleri giderilmiş serilerde yıllar arasındaki bağımlılık zayıf olduğundan etkin örneklem büyüklüğü ($n_e$ff) 40–44 arasında değişmiştir. Elde edilen ilişkilerin güvenilirliği Spearman sıra korelasyonu, 10.000 yinelemeli bootstrap güven aralıkları, bir yılı dışarıda bırakma (LOO) testi, tersil karşılaştırmaları ve 21 yıllık kayan pencerelerle sınanmıştır. Atmosferik dolaşım ve yaz yağışlarının etkilerini ayırt etmek amacıyla kısmi korelasyon ve standartlaştırılmış çoklu regresyon analizleri uygulanmıştır. Modellerin tahmin başarısı ve aşırı uyuma duyarlılığı, LOO çapraz

doğrulaması ve ortalama kare hata beceri skoru (MSSS = 1 − SSE/SST) ile değerlendirilmiştir. Burada SSE çapraz doğrulama hatalarının, SST ise gözlenen anomalilerin kareler toplamını ifade etmektedir. Hücre ölçeğinde gerçekleştirilen çoklu testlerden kaynaklanabilecek yanlış anlamlılıkları sınırlandırmak amacıyla Benjamini & Hochberg (1995) tarafından önerilen yanlış keşif oranı (FDR) düzeltmesi uygulanmış ve anlamlılık düzeyi αFDR = 0,10 olarak alınmıştır.

Uzun Dönemli Eğilimler

1981–2024 döneminde İç Anadolu Bölgesi'nde en belirgin sıcaklık artışı yaz mevsiminde gerçekleşmiştir. Yaz sıcaklıkları on yılda 0,56 °C ($p < 0,001$), ilkbahar sıcaklıkları 0,43 °C ve yıllık ortalama sıcaklıklar 0,49 °C artmıştır. 1981–1990 ile 2015–2024 dönemlerinin ortalama sıcaklıkları arasındaki fark ise 1,8 °C'ye ulaşmıştır. İncelenen 44 yıllık dönemin en sıcak yazı 23,3 °C ortalamayla 2024 yılında yaşanmış, bu yılı sırasıyla 2010, 2007, 2016 ve 2006 izlemiştir. Isınma eğilimi bölgenin tamamında istatistiksel olarak anlamlıdır. Grid hücrelerinin %90'ında sıcaklık artışı on yılda 0,45–0,68 °C arasında değişmektedir (Şekil 2c). Türkeş et al. (2002) tarafından 1929–1999 döneminde Türkiye'nin iç kesimlerinde ortalama yaz sıcaklıklarında azalma eğilimi belirlenmiş olması, bölgedeki yaz ısınmasının 1980'lerden itibaren belirginleştiğini düşündürmektedir. İç Anadolu'daki meteoroloji istasyonlarının 1960–2021 dönemi kayıtlarına dayanan bulgular da bu değerlendirmeyi desteklemektedir (Bayer-Altın, 2023).

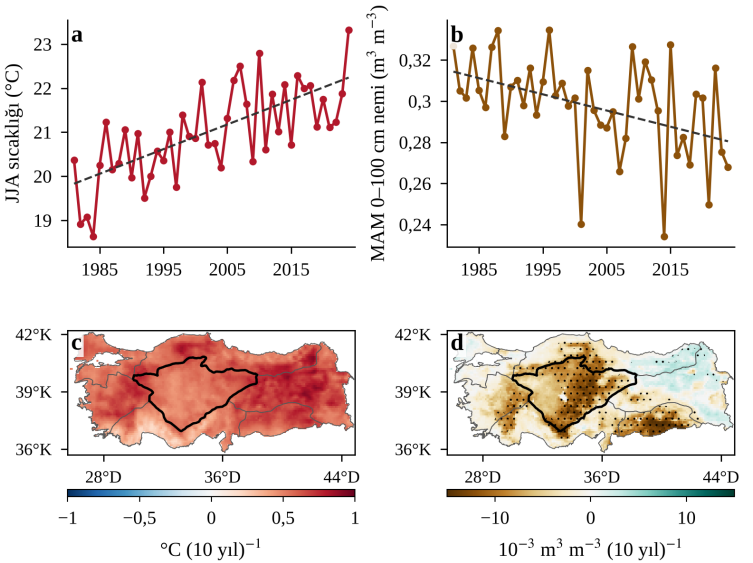
İlkbahar toprak neminde ise incelenen bütün derinliklerde istatistiksel olarak anlamlı azalma eğilimleri belirlenmiştir. On yıllık azalma miktarı 0–7 ve 7–28 cm katmanlarında −0,0077 $m^3\ m^{-3}$, 28–100 cm katmanında ise −0,0083 $m^3\ m^{-3}$ olarak hesaplanmıştır ($p \leq 0,015$). Toprağın ilk 100 cm'lik kesitinde 44 yıl boyunca meydana gelen toplam azalma yaklaşık 0,035 $m^3\ m^{-3}$ olup bu değer, yıllar arası

standart sapmanın 1,5 katına karşılık gelmektedir. Bununla birlikte, toprak nemindeki azalma bölge genelinde aynı şiddette gerçekleşmemiştir. Grid hücrelerinin %99'unda negatif eğilim belirlenmesine karşın bunların yalnızca %63'ünde azalma istatistiksel olarak anlamlıdır. Anlamlı kuruma eğilimleri özellikle bölgenin kuzey ve orta kesimlerinde, 33,5°–36,5° doğu boylamları arasında yoğunlaşmaktadır (Şekil 2d). Doğu Karadeniz ve Kuzeydoğu Anadolu'da ise toprak nemi eğilimleri daha zayıf olup bazı alanlarda artış göstermektedir.

Toprak nemindeki azalmanın yalnızca yağış değişimleriyle açıklanması güçtür. Yıllık toplam yağışta on yılda 15,1 mm azalma belirlenmiş olmakla birlikte bu eğilim istatistiksel anlamlılık sınırına yakındır ($p = 0,053$). İlkbahar ve yaz yağışlarında ise anlamlı bir değişim görülmemiştir. Aynı dönemde bölgesel yaz (JJA) Z500 değerleri on yılda 7,7 gpm yükselmiş ($p < 0,001$), ilkbahar sıcaklıkları ise 0,43 °C artmıştır. İlkbahardaki sıcaklık artışının atmosferin buharlaşma talebini artırarak toprak nemindeki azalmaya katkıda bulunmuş olması mümkündür. Ancak mevcut veriler, toprak nemindeki azalmada yağış ve sıcaklık değişimlerinin göreli katkılarını kesin olarak belirlemeye yeterli değildir.

Şekil 2. İç Anadolu Bölgesi'nde (a) yaz mevsimi ortalama sıcaklıklarının ve (b) ilkbahar kök bölgesi toprak neminin yıllar arasındaki değişimi ile (c) yaz sıcaklığı ve (d) ilkbahar kök bölgesi

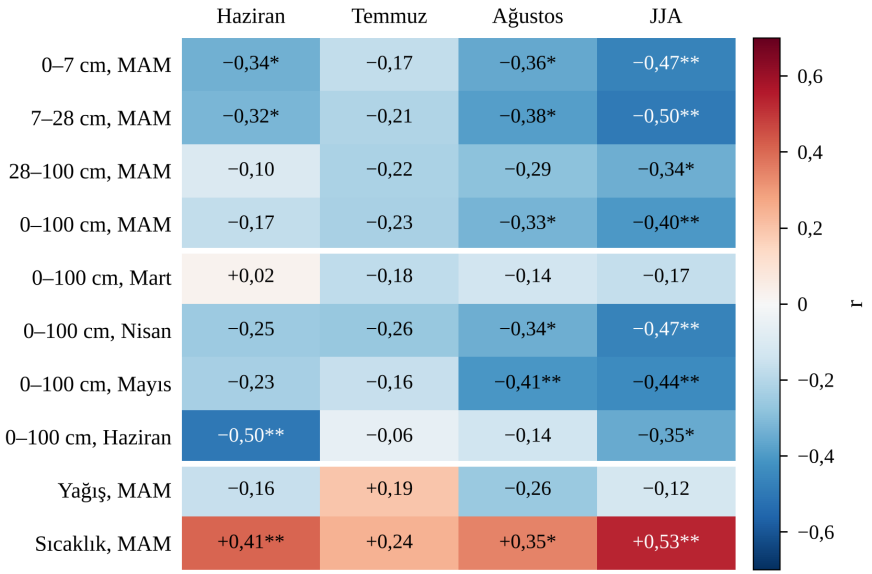
toprak nemine ait uzun dönemli eğilimlerin mekânsal dağılımı (1981–2024).



İlkbahar Toprak Nemi ile Yaz Sıcaklığı Arasındaki İlişki

Doğrusal eğilimleri giderilmiş zaman serilerinde ilkbahar toprak nemi ile yaz sıcaklıkları arasında bütün derinliklerde negatif korelasyon belirlenmiştir (Şekil 3). En güçlü ilişki 7–28 cm katmanında görülmüş ($r = -0{,}50$; $p = 0{,}001$; Spearman $\rho = -0{,}45$), korelasyon katsayıları 0–7 cm katmanında −0,47, 0–100 cm kesitinde −0,40 ve 28–100 cm katmanında −0,34 olarak hesaplanmıştır. 7–28 cm katmanı için %95 bootstrap güven aralığı −0,68 ile −0,25 arasında değişmektedir. Aynı katmanda ilkbahar toprak neminin 0,01 $m^3\ m^{-3}$ azalması, yaz sıcaklığında ortalama 0,18 ± 0,05 °C artışla ilişkili bulunmuştur.

Şekil 3. Farklı toprak derinliklerindeki nem koşulları, ilkbahar yağışı ve sıcaklığı ile yaz aylarının hava sıcaklıkları arasındaki korelasyonlar.



İlkbahar ayları ayrı ayrı değerlendirildiğinde Mart ayındaki toprak nemi ile yaz sıcaklığı arasında anlamlı bir ilişki bulunmazken ($r = -0,17$), Nisan ($r = -0,47$) ve Mayıs ($r = -0,44$) aylarında bu ilişki belirginleşmektedir. Yaz mevsiminde ise en güçlü ilişki Ağustos ayında ($r = -0,33$ ile $-0,41$), en zayıf ilişki Temmuz ayında görülmektedir. Haziran sıcaklıkları daha çok aynı ayın toprak nemiyle ilişkili olup korelasyon katsayısı −0,50'dir. Buna karşılık ilkbahar yağışları ile yaz sıcaklıkları arasındaki ilişki zayıf ve istatistiksel olarak anlamsızdır ($r = -0,12$). Avrupa'da yapılan araştırmalarda da toprak nemi ile standart yağış indisi arasında zayıf ilişkiler belirlenmiştir (Whan et al., 2015). Bu durum, yaz sıcaklıkları açısından yalnızca önceki aylarda düşen yağışın değil, yağış ve buharlaşma koşullarının toprakta oluşturduğu toplam nem birikiminin de önemli olduğunu göstermektedir.

İlkbahardaki toprak neminin yaz aylarına kadar korunma eğilimi derinlikle birlikte artmaktadır. İlkbahar (MAM) ve yaz (JJA) toprak nemi arasındaki korelasyon 0–7 cm katmanında 0,48, 7–28

cm katmanında 0,56 ve 28–100 cm katmanında 0,66 olarak hesaplanmıştır. Toprak neminin mevsimler arasındaki sürekliliği derin katmanlarda daha güçlü olmasına rağmen yaz sıcaklığıyla en yüksek korelasyonun 7–28 cm katmanında görülmesi dikkat çekicidir. Bu durum, söz konusu katmanın ilkbahardan yaza kadar nemini kısmen koruyabilmesi ve aynı zamanda buharlaşma-terleme süreçlerine katılan kök bölgesinin üst kesiminde bulunmasıyla ilişkili olabilir.

İlkbahar toprak nemi ile yaz mevsimi Z500 indeksi arasında anlamlı bir ilişki belirlenmemiştir (7–28 cm için r = −0,07). Atmosferik dolaşımın etkisi kontrol edildiğinde ise toprak nemi ile yaz sıcaklığı arasındaki ilişki zayıflamak yerine güçlenmiş ve kısmi korelasyon katsayısı −0,63'e ulaşmıştır (Tablo 1). Z500 indeksi tek başına yaz sıcaklıklarındaki değişkenliğin %50'sini açıklarken modele 7–28 cm ilkbahar toprak neminin eklenmesiyle bu oran %70'e yükselmiştir. Çapraz doğrulama sonucunda model beceri skorunun 0,46'dan 0,66'ya çıkması, toprak neminin modelin tahmin başarısına da katkı sağladığını göstermektedir. Toprak neminin standartlaştırılmış regresyon katsayısı (β = −0,45), atmosferik dolaşımın katsayısının (β = 0,68) yaklaşık üçte ikisi büyüklüğündedir. Yaz yağışlarının da modele dâhil edilmesiyle açıklanan varyans %72'ye yükselmiş, ancak yağış değişkeninin katkısı istatistiksel olarak anlamlı bulunmamıştır (p = 0,13).

Tablo 1. Yaz sıcaklığının ilkbahar toprak nemi ve yaz dolaşımıyla ilişkisi (eğilimden arındırılmış seriler, n = 44)

İlişki ya da model	7–28 cm	0–100 cm
r (MAM nemi; JJA sıcaklığı)	−0,50 (p = 0,001)	−0,40 (p = 0,009)
Kısmi r | JJA Z500	−0,63 (p < 0,001)	−0,50 (p = 0,001)
Kısmi r | JJA yağışı	−0,45 (p = 0,002)	−0,35 (p = 0,021)
Kısmi r | JJA Z500 ve JJA yağışı	−0,61 (p < 0,001)	−0,47 (p = 0,002)
Kısmi r | MAM sıcaklığı	−0,18 (p = 0,24)	−0,13 (p = 0,41)
R^2 (yalnızca nem)	0,25	0,16
R^2 (yalnızca Z500)	0,50	0,50
R^2 (nem ve Z500)	0,70	0,63

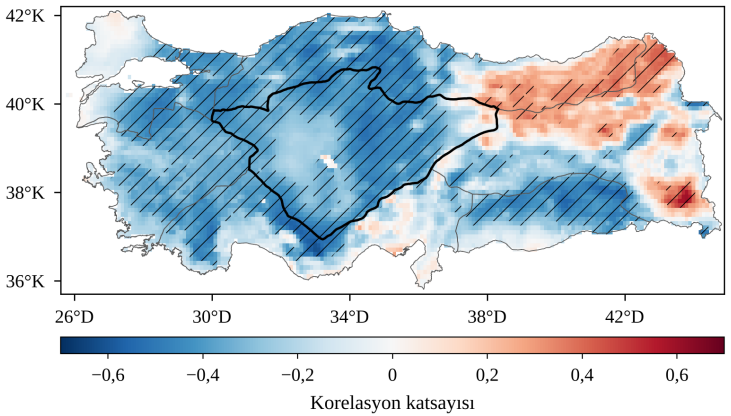
İlişki ya da model	7–28 cm	0–100 cm
β (nem; Z500)	−0,45; 0,68	−0,35; 0,68
LOO r (MSSS), yalnızca Z500	0,68 (0,46)	0,68 (0,46)
LOO r (MSSS), nem ve Z500	0,81 (0,66)	0,76 (0,57)

Tablo 1'deki bulgular arasında özellikle ilkbahar sıcaklığının etkisi dikkat çekmektedir. İlkbahar sıcaklığı kontrol edildiğinde, toprak nemi ile yaz sıcaklığı arasındaki ilişki zayıflamakta ve istatistiksel anlamlılığını kaybetmektedir (kısmi $r = -0,18$; $p = 0,24$). İlkbahar sıcaklığı ile 7–28 cm derinliğindeki toprak nemi arasında belirlenen güçlü negatif korelasyon ($r = -0,73$), bu iki değişkenin birbiriyle yakından ilişkili olduğunu ve yaz sıcaklıklarındaki değişkenliği açıklamada büyük ölçüde ortak bilgi taşıdığını göstermektedir.

Mekânsal Yapı ve Dolaşımın Etkisi

İlkbahar toprak nemi ile yaz sıcaklığı arasındaki ilişki, bölgenin büyük bölümünde benzer özellikler göstermekte ve sınırlı sayıdaki grid hücresinin etkisiyle ortaya çıkmamaktadır (Şekil 4). İç Anadolu'daki hücrelerin %97'sinde ilkbahar kök bölgesi nemi ile yaz sıcaklığı arasında negatif korelasyon belirlenmiş, bölge genelindeki ortalama korelasyon katsayısı −0,35 olarak hesaplanmıştır. Yanlış keşif oranı (FDR) düzeltmesinin ardından hücrelerin %82'sinde ilişki istatistiksel olarak anlamlılığını korurken bu oran 7–28 cm toprak katmanında %90'a ulaşmaktadır. Atmosferik dolaşımın Z500 üzerinden kontrol edilmesiyle ortalama kısmi korelasyon katsayısı −0,42'ye yükselmiş, anlamlı ilişki gösteren hücrelerin oranı ise %94'e çıkmıştır.

Şekil 4. İlkbahar kök bölgesi nemi ile yaz sıcaklığı arasındaki korelasyonun dağılımı



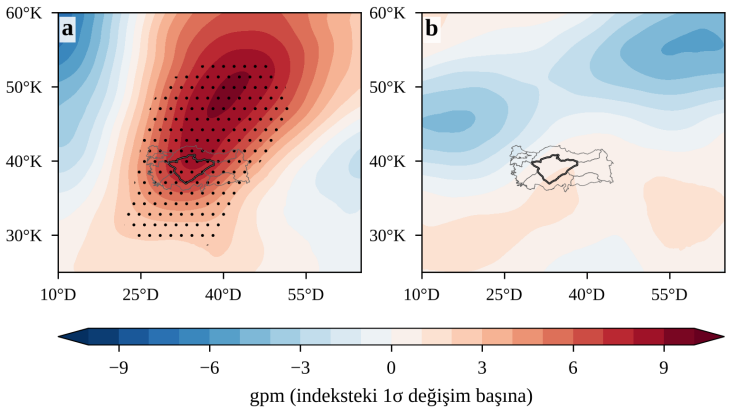
İlkbahar toprak nemi ile yaz sıcaklığı arasındaki negatif ilişki yalnızca İç Anadolu ile sınırlı kalmayıp Ege'nin iç kesimleri, Batı Karadeniz'in iç bölümleri ve Güneydoğu Anadolu'yu kapsayan geniş bir alanda da görülmektedir. Buna karşılık Doğu Karadeniz ve Kuzeydoğu Anadolu'da korelasyon pozitif değerlere ulaşmaktadır. Nemli bölgelerde buharlaşmanın daha çok mevcut enerjiyle sınırlandırılması, toprak nemi ile sıcaklık arasındaki ilişkinin zayıflamasıyla uyumludur (Seneviratne et al., 2010). Yüksek kesimlerde ise ilkbahar toprak neminin kar erimesinden etkilenmesi, ilişkinin yönünü ve gücünü değiştirmiş olabilir. Ancak bu olasılık mevcut çalışmada ayrıca sınanmamıştır. İç Anadolu'da en zayıf ilişkilerden bazıları Tuz Gölü çevresindeki kurak alanlarda görülmektedir. Hücre ölçeğinde korelasyonun gücü, ilkbahar toprak neminin yıllar arasındaki değişkenliğiyle zayıf bir ilişki gösterirken (Spearman $\rho = -0{,}26$), yükseltiyle herhangi bir ilişki belirlenmemiştir ($\rho = 0{,}00$).

Yaz sıcaklığı ile bölgesel Z500 indeksi arasında güçlü bir pozitif korelasyon bulunmaktadır ($r = 0{,}71$). Yaz mevsimine (JJA) ait Z500 alanının bölgesel yaz sıcaklıklarıyla regresyonu, İç

Anadolu’dan kuzeydoğuya doğru uzanarak Hazar Denizi’nin kuzeyine ulaşan ve merkezi yaklaşık 48°–50° K enlemleri ile 40°–45° D boylamları arasında bulunan belirgin bir yüksek basınç sırtını ortaya koymaktadır (Şekil 5a). Yaz sıcaklığı indeksindeki bir standart sapmalık (1σ) artış, bu sırtın merkezinde yaklaşık 9 gpm, İç Anadolu üzerinde ise 7,6 gpm jeopotansiyel yükseklik artışıyla ilişkilidir. Sıcak yazların bu tür atmosferik sırt koşullarıyla birlikte görülmesi, 2007 yazında yaşanan aşırı sıcaklıkların atmosferik bloklanma ve sıcak hava dalgalarıyla ilişkilendirildiği bulgularla da örtüşmektedir (Demirtaş, 2018).

Aynı regresyon analizi ilkbahar toprak nemi için tekrarlandığında, kurak geçen ilkbaharları izleyen yaz aylarında Z500 alanında istatistiksel olarak anlamlı bir anomali belirlenmemiştir (Şekil 5b). Regresyon katsayıları İç Anadolu üzerinde 1 gpm’nin, incelenen alanın tamamında ise 1,5 gpm’nin altında kalmaktadır. İlkbahar ve yaz dönemlerine ait Z500 indeksleri arasında da anlamlı bir ilişki bulunmamıştır (r = 0,09). Bu bulgular, ilkbahar toprak nemi ile yaz sıcaklığı arasındaki ilişkinin atmosferik dolaşım koşullarının mevsimler boyunca devam etmesiyle açıklanamadığını göstermektedir. Avrupa’da gerçekleştirilen model deneylerinde, toprak nemindeki azalmanın orta troposferdeki jeopotansiyel yükseklik anomalilerini güçlendirebildiği belirtilmiştir (Fischer et al., 2007). Ancak İç Anadolu’ya ait aylık verilerde benzer bir etkiye rastlanmamıştır. Elde edilen sonuçlar, toprak neminin yaz sıcaklıkları üzerindeki olası etkisinin büyük ölçekli atmosferik dolaşımdan çok, yerel yüzey enerji dengesiyle ilişkili olabileceğine işaret etmektedir.

Şekil 5. Eğilimden arındırılmış JJA Z500 alanının (a) İç Anadolu yaz sıcaklığı indeksine ve (b) işareti ters çevrilmiş ilkbahar kök bölgesi nemi indeksine regresyonu



Bulguların Güvenilirliği ve Yükseltiye Bağlı Farklılıklar

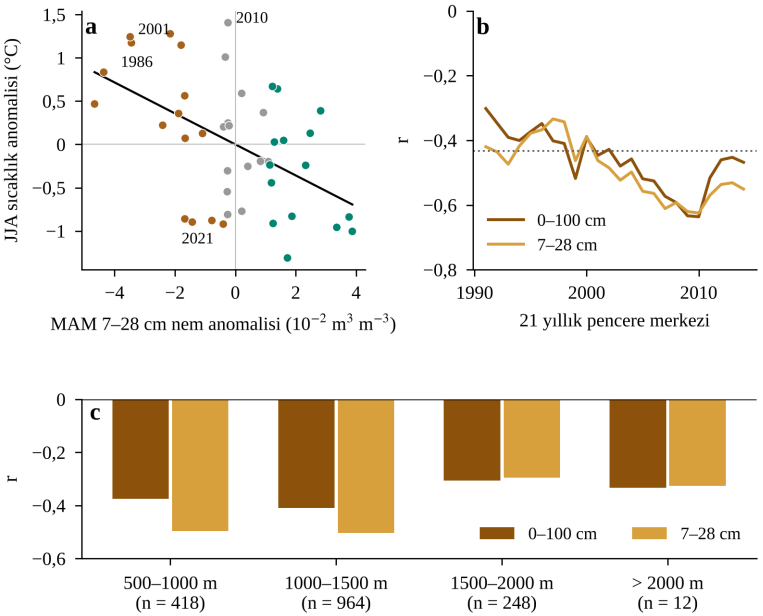
İlkbaharda 7–28 cm katmanındaki toprak nemine göre belirlenen 15 kurak yılı izleyen yazların ortalama sıcaklık anomalisi +0,26 °C, 15 nemli yılı izleyen yazlarınki ise −0,33 °C olarak hesaplanmıştır. İki grup arasındaki 0,59 °C'lik fark, hem t testine ($p = 0,037$) hem de Mann-Whitney U testine ($p = 0,042$) göre istatistiksel olarak anlamlıdır (Şekil 6a) Kurak ilkbaharların ardından yazların %53'ü en sıcak üçte birlik grupta yer alırken nemli ilkbaharlardan sonra bu oran %20'ye düşmektedir. İlkbahar kuraklığı, sıcak bir yaz yaşanacağını tek başına belirlememekle birlikte, yaz aylarında yüksek sıcaklıkların görülme olasılığını artırabilmektedir (Mueller & Seneviratne, 2012).

İlkbahar toprak nemi ile yaz sıcaklığı arasındaki korelasyon, 21 yıllık kayan dönemlerde 0–100 cm katmanı için −0,30 ile −0,64, 7–28 cm katmanı için ise −0,33 ile −0,62 arasında değişmiştir. İncelenen dönemlerin hiçbirinde ilişkinin yönü değişmemiş, en güçlü negatif korelasyonlar merkez yılları 2009–2010 olan dönemlerde görülmüştür (Şekil 6b). İlişkinin zamanla güçlenmesi,

bölgede toprak neminin buharlaşmayı sınırladığı koşulların daha sık yaşanmasıyla ilişkili olabilir. Ancak 21 yıllık dönemlerin taşıdığı belirsizlik, bu bulgunun bir rejim değişikliği olarak yorumlanmasına yeterli değildir. Bir yılı dışarıda bırakma (LOO) sınamasında da 7–28 cm katmanına ait korelasyon katsayısı −0,53 ile −0,46 arasında kalarak ilişkinin belirli yıllara bağlı olmadığını göstermiştir.

Yükselti basamaklarına göre yapılan değerlendirmede, toprak nemi ile yaz sıcaklığı arasındaki ilişkinin önemli ölçüde değişmediği görülmüştür (Şekil 6c). 7–28 cm katmanındaki korelasyon katsayısı 500–1000 m ve 1000–1500 m yükselti basamaklarında −0,50 olarak hesaplanırken toprak neminin daha yüksek ve yıllar arasındaki değişkenliğinin daha düşük olduğu 1500–2000 m basamağında −0,30'a gerilemiştir. Yaz sıcaklıklarındaki artış ise bütün yükselti basamaklarında benzer düzeyde olup on yılda 0,53–0,58 °C arasında değişmektedir. Yalnızca 12 grid hücresinden oluşan 2000 m üzerindeki yükselti basamağı, örneklem sayısının sınırlı olması nedeniyle değerlendirme dışında tutulmuştur.

Şekil 6. İlkbahar toprak nemi ile yaz sıcaklıkları arasındaki ilişkinin değerlendirilmesi: (a) toprak nemi ve yaz sıcaklığı anomalileri, (b) 21 yıllık kayan dönemlerde korelasyonun değişimi ve (c) yükselti basamaklarına göre korelasyon katsayıları(2000 m üzerindeki sonuçlar sınırlı örneklem nedeniyle yorumlanmamıştır).



Tartışma

Elde edilen bulgular, İç Anadolu'da ilkbahar sonunda toprakta bulunan suyun yaz sıcaklıklarını etkileyebilecek bir nem belleği oluşturduğunu düşündürmektedir. Kurak geçen ilkbaharların ardından toprak neminin buharlaşmayı sınırlayan düzeylere daha erken gerilemesi, yüzey enerji dengesinde duyulur ısı akısının payını artırarak atmosferik sınır tabakasının daha fazla ısınmasına neden olabilir (Miralles et al., 2019; Seneviratne et al., 2010). Toprak nemi ile sıcaklık arasındaki ilişkinin Temmuz ayında zayıflayıp Ağustos ayında güçlenmesi de bu mekanizmayla uyumludur. Temmuz sıcaklıklarının belirlenmesinde atmosferik dolaşım koşulları daha etkili olurken Ağustos ayında toprakta kalan su miktarının yüzey enerji dengesi üzerindeki etkisi belirginleşiyor olabilir. Ancak bu mekanizmanın doğrulanabilmesi için günlük ölçekteki yüzey enerji akılarının incelenmesi gerekmektedir.

Toprak nemi ve atmosferik dolaşım koşullarının birbirinden büyük ölçüde bağımsız değişmesi, aşırı sıcak yazların farklı koşullar

altında ortaya çıkabildiğini göstermektedir. Doğrusal eğilimleri giderilmiş seride en sıcak yaz olan 2010 yılında (+1,41 °C), ilkbahar toprak nemi normale yakın olmasına rağmen güçlü bir atmosferik sırt (+0,9σ) etkili olmuştur. Buna karşılık 2001 (+1,24 °C) ve 1986 (+1,17 °C) yazları, 7–28 cm katmanındaki toprak neminin normalin 1,7 standart sapma altında (−1,7σ) olduğu kurak ilkbaharları izlemiştir. Ham sıcaklık serisinde en yüksek değerin kaydedildiği 2024 yazında ise kurak bir ilkbahar (−0,9σ) ile inceleme döneminin en güçlü atmosferik sırtlarından biri (+1,8σ) birlikte görülmüştür. Bu farklı örnekler, yaz sıcaklıklarının oluşumunda toprak nemi ve atmosferik dolaşımın birlikte değerlendirilmesi gerektiğini göstermekte ve kuru toprak koşulları ile kalıcı basınç düzenlerinin ortak etkisini ortaya koyan çalışmalarla örtüşmektedir (Miralles et al., 2014).

Çalışmanın sonuçlarını yorumlarken dikkate alınması gereken en önemli sınırlılıklardan biri, ilkbahar sıcaklığının toprak nemiyle olan güçlü ilişkisidir. İlkbahar sıcaklığı kontrol edildiğinde toprak nemi ile yaz sıcaklığı arasındaki ilişkinin anlamlılığını kaybetmesi farklı mekanizmalarla açıklanabilir. İlkbahardaki sıcaklık artışı buharlaşma talebini yükselterek toprak nemini azaltıyor ve bu nem kaybı yaz sıcaklıklarını etkiliyorsa toprak nemi, sıcaklığın mevsimler arasındaki etkisini taşıyan bir aracı değişken olarak değerlendirilebilir. Böyle bir durumda ilkbahar sıcaklığının istatistiksel olarak kontrol edilmesi, toprak nemi üzerinden gerçekleşen etkinin de kısmen ortadan kaldırılmasına neden olabilir. Bununla birlikte, Akdeniz ve Karadeniz'in yüzey suyu sıcaklıkları veya bitki örtüsü gibi daha yavaş değişen çevresel koşulların da ilkbahardaki sıcaklık özelliklerinin yaz aylarına taşınmasında rol oynaması mümkündür. İlkbahar ve yaz Z500 indeksleri arasında anlamlı bir ilişki bulunmaması, sıcaklık koşullarının mevsimler arasındaki sürekliliğinin yalnızca atmosferik dolaşımla açıklanmasını güçleştirmektedir. Toprak nemi bu sürekliliği

sağlayabilecek önemli bir yüzey değişkeni olmakla birlikte, tek etken olduğu söylenemez. Nitekim kök bölgesi nemi kontrol edildiğinde de ilkbahar sıcaklığı ile yaz sıcaklığı arasındaki ilişki devam etmektedir (kısmi r = 0,40). Bu durum, ERA5-Land toprak nemi verilerinin söz konusu etkileşimin tamamını temsil edememesinden veya başka süreçlerin de etkili olmasından kaynaklanabilir. Bu etkilerin birbirinden ayrılabilmesi için toprak neminin sabit tutulduğu ve serbestçe değişmesine izin verildiği iklim modeli deneylerine ihtiyaç vardır (Fischer et al., 2007). Dolayısıyla mevcut bulgular, nedenselliği kesin olarak ortaya koyan sonuçlardan ziyade istatistiksel ilişkiler olarak değerlendirilmelidir.

Kullanılan veri setinin özellikleri de sonuçların yorumlanmasında bazı sınırlılıklar oluşturmaktadır. ERA5-Land'in 2 m hava sıcaklığı, yükselti farklarına göre düzeltilmiş ERA5 atmosferik verilerinden türetildiği için büyük ölçüde ERA5'in temsil ettiği atmosfer koşullarını yansıtmaktadır. Toprak nemi ise aynı meteorolojik koşullar altında kara yüzeyi modeli tarafından hesaplanmakta ve doğrudan gözlem verileriyle güncellenmemektedir (Muñoz-Sabater et al., 2021). Ayrıca İç Anadolu için ERA5-Land toprak nemi verilerinin yerinde ölçümlerle doğrulanması bu çalışma kapsamında gerçekleştirilmemiştir. Özellikle Konya Ovası'nda ve bölgenin diğer tarım alanlarında yaz aylarında uygulanan yoğun sulama, model sonuçlarını etkileyebilecek bir başka unsurdur. Kullanılan kara yüzeyi modelinde sulama süreçlerinin temsil edilmemesi, tarım alanlarındaki gerçek toprak nemi koşulları ile model değerleri arasında farklılıklara yol açabilir. Bunun yanında, çalışma alanının idari bölge sınırlarına göre belirlenmiş olması iklimsel bakımdan farklı özellikler taşıyan alanların birlikte değerlendirilmesine neden olmaktadır (Unal et al., 2003). Aylık ortalama sıcaklıkların kullanılması da sıcak hava dalgalarının ve aşırı yüksek sıcaklıkların ayrıntılı biçimde incelenmesini sınırlandırmaktadır. Toprak neminin

sıcaklık üzerindeki etkisinin özellikle aşırı sıcak koşullarda güçlendiği dikkate alındığında (Hirschi et al., 2011; Mueller & Seneviratne, 2012; Whan et al., 2015), bu çalışmada aylık ortalamalardan elde edilen ilişkilerin söz konusu etkileşimin bütün boyutlarını yansıtmadığı düşünülmektedir.

İlkbahar toprak neminin Mayıs ayı sonunda bilinen bir değişken olması, yaz sıcaklıklarının mevsimsel tahmini açısından önem taşımaktadır. Çapraz doğrulama sonuçlarında ilkbahar toprak nemi tek başına yaz sıcaklığıyla 0,43 düzeyinde bir ilişki göstermiştir. Bu ilişkinin atmosferik dolaşımdan büyük ölçüde bağımsız olması, toprak neminin mevsimsel tahminlere ek bilgi sağlayabileceğine işaret etmektedir. Yıllar arasındaki değişimlerden hesaplanan sıcaklık duyarlılığı uzun dönemli toprak nemi eğilimine uygulandığında, 7–28 cm katmanındaki kurumanın on yılda yaklaşık 0,14 °C'lik bir sıcaklık artışına karşılık geldiği görülmektedir. Bu miktar, bölgede gözlenen yaz ısınmasının yaklaşık dörtte birine eşittir. Ancak toprak nemindeki azalmanın da kısmen sıcaklık artışından kaynaklanabileceği göz önünde bulundurulduğunda, hesaplanan bu değer doğrudan nedensel bir katkı olarak değil, olası etkinin üst sınırına ilişkin bir tahmin olarak değerlendirilmelidir.

Sonuç

ERA5-Land ve ERA5 verileri kullanılarak gerçekleştirilen bu çalışmada, İç Anadolu Bölgesi'nde ilkbahar toprak nemi ile yaz sıcaklıkları arasında atmosferik dolaşım koşullarından büyük ölçüde bağımsız, mekânsal açıdan tutarlı ve istatistiksel olarak anlamlı bir gecikmeli ilişki belirlenmiştir. 1981–2024 döneminde yaz sıcaklıkları on yılda 0,56 °C artarken ilkbahar kök bölgesi toprak nemi aynı sürede yaklaşık 0,008 m^3 m^{-3} azalmıştır. Doğrusal eğilimlerin giderilmesinin ardından en güçlü ilişki 7–28 cm toprak katmanında ve özellikle Nisan-Mayıs aylarında görülmüştür ($r = -0,50$). Yaz mevsimindeki atmosferik dolaşımın Z500 üzerinden kontrol edilmesiyle ilişki daha da güçlenmiş (kısmi $r = -0,63$),

toprak nemi ve Z500 değişkenleri birlikte yaz sıcaklıklarındaki değişkenliğin %70'ini açıklamıştır. Kurak ilkbaharları izleyen yazların, nemli ilkbaharları izleyenlere göre ortalama 0,59 °C daha sıcak olduğu ve yaz sıcaklıklarının en yüksek üçte birlik grupta yer alma oranının %20'den %53'e yükseldiği belirlenmiştir.

Bununla birlikte, ilkbahar sıcaklığı ile toprak nemi arasındaki güçlü ilişki, bu iki değişkenin yaz sıcaklıkları üzerindeki bağımsız etkilerinin mevcut gözlemsel verilerle kesin olarak ayrılmasını güçleştirmektedir. Bu nedenle toprak neminin yaz sıcaklıkları üzerindeki olası nedensel etkisinin açıklığa kavuşturulabilmesi için farklı toprak nemi koşullarının uygulandığı iklim modeli deneylerine, günlük en yüksek sıcaklıkları esas alan ayrıntılı analizlere ve yerinde toprak nemi ölçümleriyle gerçekleştirilecek doğrulama çalışmalarına ihtiyaç bulunmaktadır.

Kaynakça/References

Bayer-Altın, T. (2023). Long-term trends and variability in air temperatures of central Anatolia region, Turkey, for the period 1960–2021. *Acta Geophysica, 71*(4), 2031–2047. https://doi.org/10.1007/s11600-023-01077-6

Benjamini, Y., & Hochberg, Y. (1995). Controlling the false discovery rate: A practical and powerful approach to multiple testing. *Journal of the Royal Statistical Society: Series B (Methodological), 57*(1), 289–300. https://doi.org/10.1111/j.2517-6161.1995.tb02031.x

Bretherton, C. S., Widmann, M., Dymnikov, V. P., Wallace, J. M., & Bladé, I. (1999). The effective number of spatial degrees of freedom of a time-varying field. *Journal of Climate, 12*(7), 1990–2009. https://doi.org/10.1175/15200442(1999)012<1990:TENOSD>2.0.CO;2

Demirtaş, M. (2018). The high-impact 2007 hot summer over Turkey: Atmospheric-blocking and heat-wave episodes. *Meteorological Applications, 25*(3), 406–413. https://doi.org/10.1002/met.1708

European Centre for Medium-Range Weather Forecasts. (2026, June 8). *Conversion table for accumulated variables (total precipitation/fluxes)*. Copernicus Knowledge Base. https://confluence.ecmwf.int/spaces/CKB/pages/197702790/Conversion+table+for+accumulated+variables+total+precipitation+fluxes

Fischer, E. M., Seneviratne, S. I., Vidale, P. L., Lüthi, D., & Schär, C. (2007). Soil moisture–atmosphere interactions during the 2003 European summer heat wave. *Journal of Climate, 20*(20), 5081–5099. https://doi.org/10.1175/JCLI4288.1

Hamed, K. H., & Rao, A. R. (1998). A modified Mann-Kendall trend test for autocorrelated data. *Journal of Hydrology, 204*(1–4), 182–196. https://doi.org/10.1016/S0022-1694(97)00125-X

Hersbach, H., Bell, B., Berrisford, P., Hirahara, S., Horányi, A., Muñoz-Sabater, J., Nicolas, J., Peubey, C., Radu, R., Schepers, D., Simmons, A., Soci, C., Abdalla, S., Abellan, X., Balsamo, G., Bechtold, P., Biavati, G., Bidlot, J., Bonavita, M., . . . Thépaut, J.-N. (2020). The ERA5 global reanalysis. *Quarterly Journal of the Royal Meteorological Society, 146*(730), 1999–2049. https://doi.org/10.1002/qj.3803

Hirschi, M., Seneviratne, S. I., Alexandrov, V., Boberg, F., Boroneant, C., Christensen, O. B., Formayer, H., Orlowsky, B., & Stepanek, P. (2011). Observational evidence for soil-moisture impact on hot extremes in southeastern Europe. *Nature Geoscience, 4*(1), 17–21. https://doi.org/10.1038/ngeo1032

Koster, R. D., & Suarez, M. J. (2001). Soil moisture memory in climate models. *Journal of Hydrometeorology, 2*(6), 558–570. https://doi.org/10.1175/1525
7541(2001)002<0558:SMMICM>2.0.CO;2

Mann, H. B. (1945). Nonparametric tests against trend. *Econometrica, 13*(3), 245–259. https://doi.org/10.2307/1907187

Materia, S., Ardilouze, C., Prodhomme, C., Donat, M. G., Benassi, M., Doblas-Reyes, F. J., Peano, D., Caron, L.-P., Ruggieri, P., & Gualdi, S. (2022). Summer temperature response to extreme soil water conditions in the Mediterranean transitional climate regime. *Climate Dynamics, 58*(7–8), 1943–1963. https://doi.org/10.1007/s00382-021-05815-8

Miralles, D. G., Teuling, A. J., van Heerwaarden, C. C., & Vilà-Guerau de Arellano, J. (2014). Mega-heatwave temperatures due to combined soil desiccation and atmospheric heat accumulation.

Nature Geoscience, 7(5), 345–349. https://doi.org/10.1038/ngeo2141

Miralles, D. G., Gentine, P., Seneviratne, S. I., & Teuling, A. J. (2019). Land–atmospheric feedbacks during droughts and heatwaves: State of the science and current challenges. *Annals of the New York Academy of Sciences, 1436*(1), 19–35. https://doi.org/10.1111/nyas.13912

Mueller, B., & Seneviratne, S. I. (2012). Hot days induced by precipitation deficits at the global scale. *Proceedings of the National Academy of Sciences, 109*(31), 12398–12403. https://doi.org/10.1073/pnas.1204330109

Muñoz-Sabater, J., Dutra, E., Agustí-Panareda, A., Albergel, C., Arduini, G., Balsamo, G., Boussetta, S., Choulga, M., Harrigan, S., Hersbach, H., Martens, B., Miralles, D. G., Piles, M., Rodríguez-Fernández, N. J., Zsoter, E., Buontempo, C., & Thépaut, J.-N. (2021). ERA5-Land: A state-of-the-art global reanalysis dataset for land applications. *Earth System Science Data, 13*(9), 4349–4383. https://doi.org/10.5194/essd-13-4349-2021

Quesada, B., Vautard, R., Yiou, P., Hirschi, M., & Seneviratne, S. I. (2012). Asymmetric European summer heat predictability from wet and dry southern winters and springs. *Nature Climate Change, 2*(10), 736–741. https://doi.org/10.1038/nclimate1536

Sen, P. K. (1968). Estimates of the regression coefficient based on Kendall's tau. *Journal of the American Statistical Association, 63*(324), 1379–1389. https://doi.org/10.1080/01621459.1968.10480934

Seneviratne, S. I., Corti, T., Davin, E. L., Hirschi, M., Jaeger, E. B., Lehner, I., Orlowsky, B., & Teuling, A. J. (2010). Investigating soil moisture–climate interactions in a changing climate: A review.

Earth-Science Reviews, 99(3–4), 125–161. https://doi.org/10.1016/j.earscirev.2010.02.004

Seneviratne, S. I., Lüthi, D., Litschi, M., & Schär, C. (2006). Land–atmosphere coupling and climate change in Europe. *Nature, 443*(7108), 205–209. https://doi.org/10.1038/nature05095

Sönmez, F. K., Kömüşcü, A. Ü., Erkan, A., & Turgu, E. (2005). An analysis of spatial and temporal dimension of drought vulnerability in Turkey using the standardized precipitation index. *Natural Hazards, 35*(2), 243–264. https://doi.org/10.1007/s11069-004-5704-7

Türkeş, M., Sümer, U. M., & Demir, İ. (2002). Re-evaluation of trends and changes in mean, maximum and minimum temperatures of Turkey for the period 1929–1999. *International Journal of Climatology, 22*(8), 947–977. https://doi.org/10.1002/joc.777

Unal, Y., Kindap, T., & Karaca, M. (2003). Redefining the climate zones of Turkey using cluster analysis. *International Journal of Climatology, 23*(9), 1045–1055. https://doi.org/10.1002/joc.910

Unal, Y. S., Deniz, A., Toros, H., & Incecik, S. (2012). Temporal and spatial patterns of precipitation variability for annual, wet, and dry seasons in Turkey. *International Journal of Climatology, 32*(3), 392–405. https://doi.org/10.1002/joc.2274

Whan, K., Zscheischler, J., Orth, R., Shongwe, M., Rahimi, M., Asare, E. O., & Seneviratne, S. I. (2015). Impact of soil moisture on extreme maximum temperatures in Europe. *Weather and Climate Extremes, 9*, 57–67. https://doi.org/10.1016/j.wace.2015.05.001

DİKİLİ (İZMİR) İSTASYONUNDA İKLİMSEL KURAKLIĞIN UZUN DÖNEMLİ DEĞİŞİMİ: SPI–SPEI KARŞILAŞTIRMASI VE POTANSİYEL EKOLOJİK BASKILAR

Dilek Aykır[1]

Ebru Yeşim Özkan[2]

Serkan Kükrer[3]

GİRİŞ

Kuraklık; su kaynakları, tarımsal üretim, ekosistemler ve sosyoekonomik faaliyetler üzerinde geniş kapsamlı etkiler oluşturan başlıca iklimsel afetlerden biridir. Yağışların uzun süre normal değerlerin altında kalmasıyla başlayan kuraklık, sıcaklık artışı ve buna bağlı buharlaşma talebindeki yükselme nedeniyle daha şiddetli hâle gelebilmektedir. İklim değişikliği, hidrolojik döngüyü değiştirerek birçok bölgede kuraklıkların sıklığını, süresini ve şiddetini artırmaktadır. Nitekim Akdeniz Havzası, artan sıcaklıklar, azalan su mevcudiyeti ve daha uzun süreli kuraklıklar nedeniyle iklim değişikliğine karşı en duyarlı bölgelerden biri olarak kabul edilmektedir (IPCC, 2022).

SPI (Standardized Precipitation Index, Standartlaştırılmış Yağış İndeksi) ve SPEI'nin (Standardized Precipitation Evapotranspiration Index, Standartlaştırılmış Yağış-Evapotranspirasyon İndeksi) kuraklık izleme performansını karşılaştıran çalışmalar, iki indeksin genel olarak başlıca kurak ve nemli dönemleri benzer biçimde belirlediğini, ancak sıcaklığın ve atmosferik buharlaşma talebinin arttığı dönemlerde sonuçların farklılaşabildiğini göstermektedir. SPEI'yi geliştiren Vicente-Serrano vd. (2010), yağışın yanı sıra potansiyel evapotranspirasyonu dikkate alan bu indeksin özellikle küresel ısınma koşullarında kuraklık şiddetindeki değişimleri belirlemede SPI'ye göre daha duyarlı olduğunu ortaya koymuştur. Farklı iklim bölgelerinde gerçekleştirilen karşılaştırmalı araştırmalarda da kısa zaman ölçeklerinde iki indeks arasında güçlü bir uyum bulunduğu, buna karşılık uzun zaman ölçeklerinde ve sıcaklık artışının belirgin olduğu dönemlerde SPEI'nin daha şiddetli veya daha uzun süreli kuraklıklar belirleyebildiği bildirilmiştir (Tirivarombo vd., 2018; Tefera vd., 2019; Nwayor ve Robeson, 2024). Türkiye genelini inceleyen Gümüş (2023), özellikle 1990 sonrasında bazı kuraklık özelliklerinin belirlenmesinde SPI ve SPEI arasında anlamlı farklılıklar ortaya çıktığını göstermiştir. Benzer şekilde Ankara örneğinde Danandeh Mehr vd. (2020), iklim değişikliği etkilerinin değerlendirilmesinde sıcaklık değişkenliğini içeren SPEI'nin önemini vurgulamıştır. Türkiye ölçeğinde SPI, SPEI ve RDI'yi (Reconnaissance Drought Index, Keşif Kuraklık İndeksi) karşılaştıran Öz vd., (2024), indislerin belirlediği kuraklık özelliklerinin iklim bölgesine ve kullanılan zaman ölçeğine göre değişebildiğini ortaya koymuştur. Bu nedenle Dikili gibi

[1] Doç. Dr., İzmir Katip Çelebi Üniversitesi, Coğrafya Bölümü, 0000-0002-2748-4055

[2] Prof. Dr., İzmir Katip Çelebi Üniversitesi, Su Ürünleri Temel Bilimler Bölümü, 0000-0001-9780-6534

[3] Prof. Dr., İzmir Katip Çelebi Üniversitesi, Gemi ve Deniz Teknolojisi Mühendisliği Bölümü, 0000-0001-6924-3199

yaz sıcaklıklarının ve evapotranspirasyon kayıplarının yüksek olduğu Akdeniz iklimine sahip alanlarda SPI ve SPEI'nin birlikte değerlendirilmesi, yağış eksikliği ile sıcaklığa bağlı kuraklaşma etkilerinin birbirinden ayrılmasına olanak sağlamaktadır.

Türkiye'de meteorolojik kuraklığın zamansal ve mekânsal özelliklerini belirlemeye yönelik çalışmalar başlangıçta büyük ölçüde yağış verilerine ve SPI'ye dayanmıştır. Kömüşcü (1999), Türkiye genelindeki kuraklıkların mekânsal ve zamansal değişimini SPI kullanarak inceleyen öncü çalışmalardan birini gerçekleştirmiş ve kuraklık özelliklerinin ülkenin farklı iklim bölgeleri arasında önemli ölçüde değiştiğini ortaya koymuştur. Daha yakın dönemde Gümüş (2023), Türkiye'nin yedi coğrafi bölgesinde SPI ve SPEI sonuçlarını karşılaştırmış; iki indeksin genel kuraklık dönemlerini büyük ölçüde benzer şekilde belirlemesine rağmen, özellikle sıcaklığın etkili olduğu dönemlerde kuraklık şiddeti ve sınıfları bakımından farklı sonuçlar üretebildiğini göstermiştir. Öz vd., (2024) ise SPI, SPEI ve RDI indisleriyle Türkiye'deki kuraklığın zamansal-mekânsal değişimini değerlendirmiş ve kuraklık özelliklerinin kullanılan indise, zaman ölçeğine ve iklim bölgesine göre farklılaşabildiğini belirtmiştir. Türkiye'nin 1951–2022 dönemindeki kuraklıklarını SPEI ile inceleyen Erlat ve Güler (2023) de sıcaklık artışı ve evapotranspirasyon talebinin kuraklık koşullarının belirlenmesindeki önemine dikkat çekmiştir.

Ege Bölgesi özelindeki ilk çalışmalar daha çok SPI'ye dayalı meteorolojik kuraklık analizlerine odaklanmıştır. Pamuk vd. (2004), uzun süreli istasyon verilerini kullanarak Ege Bölgesi'nde farklı zaman ölçeklerindeki kuraklık koşullarını SPI ile değerlendirmiştir. Bacanlı (2017), 1960–2013 döneminde sekiz meteoroloji istasyonuna ait veriler üzerinden 1, 3, 6, 9, 12 ve 24 aylık SPI değerlerini incelemiş; kısa zaman ölçeklerinde kuraklıkların daha sık fakat daha kısa, uzun zaman ölçeklerinde ise daha seyrek fakat daha uzun süreli olduğunu belirlemiştir. Çalışmada ayrıca bölge genelinde kış yağışlarında azalma eğilimi ve son dönemlerde şiddetli kış kuraklıklarının ortaya çıkmaya başladığı bildirilmiştir (Bacanlı, 2017).

Havza ölçeğindeki çalışmalarda Eriş vd. (2020), Küçük Menderes Havzası'nda meteorolojik kuraklığın zamansal ve mekânsal değişimini inceleyerek kuraklık özelliklerinin havza içerisinde homojen olmadığını göstermiştir. Mersin vd. (2022), Ege Bölgesi'ndeki 14 meteoroloji istasyonunun 1973–2020 dönemi yağış ve sıcaklık kayıtlarını kullanarak farklı kuraklık indislerini karşılaştırmış ve indislerin aylık ölçekte genel olarak benzer kuraklık dönemleri belirlemesine karşın kuraklığın şiddeti ve süresi bakımından farklılaşabildiğini ortaya koymuştur. Araştırma, Aydın ve İzmir çevresindeki istasyonları da kapsaması bakımından Dikili çalışması için önemli bir bölgesel karşılaştırma kaynağıdır (Mersin vd., 2022).

Daha güncel çalışmalarda sıcaklığın kuraklık üzerindeki etkisi daha belirgin biçimde ele alınmaya başlanmıştır. Kayan ve Erlat (2024), Ege Bölgesi'ni temsil eden grid hücrelerine ait 1951–2022 dönemi SPEI verilerini kullanarak bölgedeki kuraklıkların uzun dönemli değişimini değerlendirmiştir. Tanrıkulu vd., (2024) ise Ege Anadolu'sundaki dokuz istasyonun 1972–2020

dönemi verileriyle 1, 3, 6, 9 ve 12 aylık SPI değerlerini incelemiş; kısa süreli kuraklıkların daha sık, uzun süreli kuraklıkların ise daha kalıcı olduğunu belirlemiştir (Tanrıkulu vd., 2024). Bu çalışmalar birlikte değerlendirildiğinde, Ege Bölgesi'nde kuraklığın farklı zaman ölçeklerinde yaygın olarak araştırıldığı; ancak kıyı Ege'deki tek bir istasyonun uzun dönemli SPI ve SPEI sonuçlarını doğrudan karşılaştıran çalışmaların görece sınırlı olduğu anlaşılmaktadır. Bu nedenle Dikili istasyonu özelinde gerçekleştirilecek karşılaştırmalı analiz, yağış eksikliği ile sıcaklık ve evapotranspirasyon kaynaklı kuraklaşma arasındaki farklılığın yerel ölçekte belirlenmesine katkı sağlayacaktır.

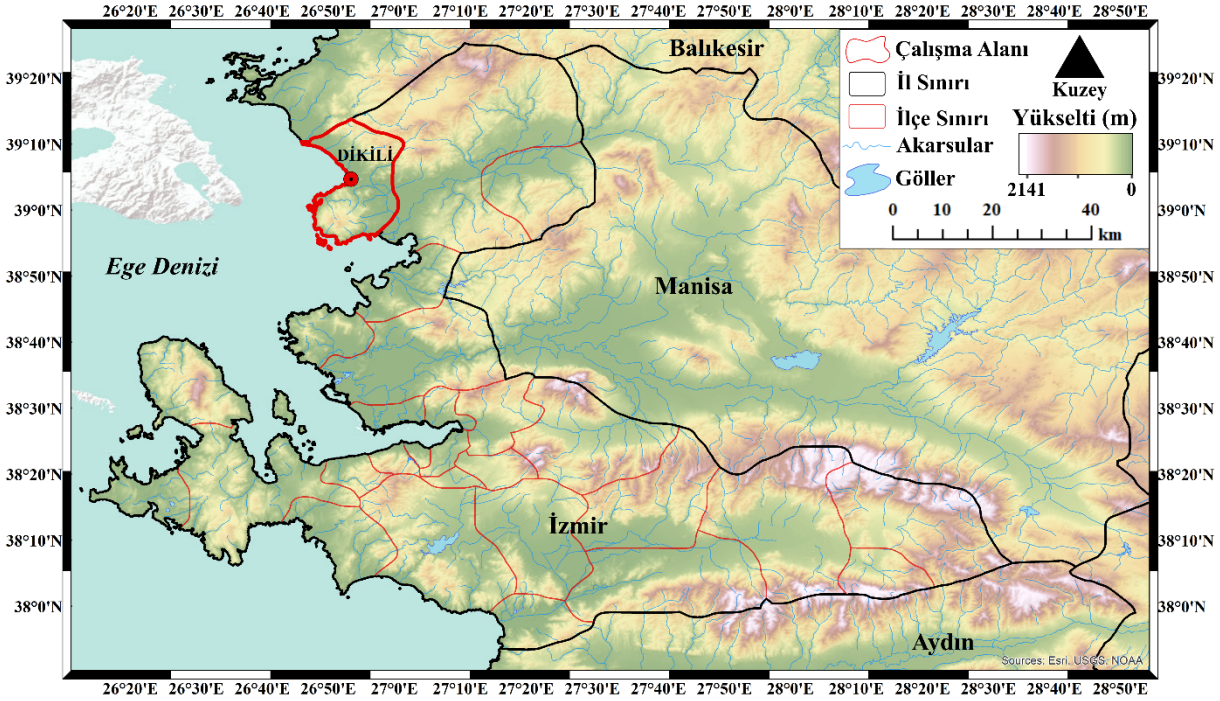
Türkiye'nin Ege kıyılarında yer alan Dikili ve çevresi de Akdeniz ikliminin belirgin mevsimselliği, yaz dönemindeki yüksek sıcaklıklar ve yağış değişkenliği nedeniyle kuraklık açısından hassas bir konumdadır. Bölgede kuraklığın zamansal özelliklerinin belirlenmesi; tarımsal faaliyetlerin sürdürülebilirliği, yüzey ve yeraltı su kaynaklarının yönetimi ve ekosistemlerin korunması bakımından önem taşımaktadır. Bu çalışmada kullanılan SPI, yalnızca yağış değişkenliğine dayalı olarak meteorolojik kuraklığı değerlendirirken; SPEI, yağışın yanı sıra potansiyel evapotranspirasyonu da dikkate almaktadır. Dolayısıyla SPI ve SPEI'nin birlikte incelenmesi, Dikili'de kuraklık koşullarının hem yağış eksikliği hem de sıcaklık artışına bağlı atmosferik su talebi açısından değerlendirilmesine ve iklim değişikliğinin kuraklık üzerindeki etkisinin daha kapsamlı biçimde ortaya konulmasına imkân sağlamaktadır.

Kuraklık, yalnızca su kaynakları ve tarımsal üretim açısından değil, ekosistemlerin yapı ve işleyişi bakımından da önemli bir iklimsel baskı oluşturmaktadır. Uzun süreli ve tekrarlayan kuraklıklar; toprak neminin azalması, bitkilerin su stresinin artması, vejetasyon üretkenliğinin düşmesi, yüzey suyu varlığının azalması ve habitat koşullarının bozulması gibi çeşitli ekolojik sonuçlara yol açabilmektedir. Bu çalışmada doğrudan ekolojik göstergeler analiz edilmemekle birlikte, Dikili istasyonunda SPI ve SPEI ile belirlenen kuraklıkların sıklık, süre ve şiddetindeki değişimler, bölgedeki ekosistemler üzerinde oluşabilecek potansiyel iklimsel baskının bir göstergesi olarak değerlendirilmektedir.

Türkiye ve Ege Bölgesi'nde kuraklığın zamansal ve mekânsal özelliklerini inceleyen çok sayıda çalışma bulunmasına rağmen, mevcut araştırmaların çoğu geniş bölgesel ölçeklere veya büyük akarsu havzalarına odaklanmaktadır. Buna karşılık, kıyı Ege'de yer alan Dikili istasyonunun uzun dönemli kuraklık özelliklerini SPI ve SPEI indisleriyle karşılaştırmalı olarak ele alan çalışmaların sınırlı olduğu görülmektedir. Dikili (Şekil 1); Akdeniz ikliminin belirgin mevsimselliği, yüksek yaz sıcaklıkları, yağışların yıl içindeki düzensiz dağılımı ve tarımsal su talebi nedeniyle kuraklık etkilerine duyarlı bir alanda bulunmaktadır. Bu nedenle istasyonun seçilmesi, yağış eksikliğine dayanan kuraklık koşulları ile sıcaklık ve potansiyel evapotranspirasyonun etkisini içeren kuraklaşma süreçlerinin yerel ölçekte birbirinden ayrılmasına imkân vermektedir. Çalışmanın özgün yönü, az çalışılmış bir kıyı Ege istasyonu olan Dikili'de SPI ve SPEI sonuçlarını karşılaştırarak yağış eksikliği ve sıcaklık artışına bağlı kuraklaşmayı birlikte değerlendirmesi ve belirlenen değişimlerin bölge

ekosistemleri üzerinde oluşturabileceği potansiyel iklimsel baskıları teorik bir çerçevede tartışmasıdır.

Şekil 1. Çalışma alanının lokasyon haritası



VERİ VE YÖNTEM

Veri Seti ve Çalışma Dönemi

Bu çalışmada, Meteoroloji Genel Müdürlüğünden (MGM) temin edilen Dikili Meteoroloji İstasyonu'na (İstasyon No: 17180) ait günlük iklim verileri kullanılmıştır. Analiz dönemi 1 Ocak 1965–31 Aralık 2025 tarihleri arasını kapsamakta ve toplam 61 yıllık gözlem süresinden oluşmaktadır. Çalışmada günlük ortalama sıcaklık (Tmean), maksimum sıcaklık (Tmax), minimum sıcaklık (Tmin) ve toplam yağış (P) değişkenleri kullanılmıştır. İstasyonun yükseltisi yaklaşık 3 m olup, potansiyel evapotranspirasyon (PET) hesaplamalarında istasyonun enlem bilgisi dikkate alınmıştır.

Analiz öncesinde veri setinin tarih sürekliliği, yinelenen kayıtlar ve fiziksel tutarlılığı kontrol edilmiştir. Veri kalite kontrolünün ardından günlük veriler, kuraklık indisleri ve potansiyel evapotranspirasyon hesaplamalarının gerektirdiği aylık zaman çözünürlüğüne dönüştürülmüştür. Bu kapsamda sıcaklık değişkenleri için günlük gözlemlerin aylık aritmetik ortalamaları, yağış için ise günlük toplamların aylık toplamları hesaplanmıştır.

Standartlaştırılmış Yağış İndisi (SPI)

Kuraklık koşullarının yağış değişkenliğine dayalı olarak değerlendirilmesi amacıyla Standartlaştırılmış Yağış İndisi (SPI) kullanılmıştır. SPI, belirli bir zaman ölçeğindeki birikimli yağış değerlerinin uzun dönemli olasılık dağılımına göre standartlaştırılması esasına dayanmakta ve farklı zaman ölçeklerinde yağış anomalilerinin karşılaştırılmasına olanak sağlamaktadır (McKee vd., 1993). Bu çalışmada aylık toplam yağış serileri üzerinden SPI-1, SPI-3, SPI-6 ve SPI-12 değerleri

hesaplanmıştır. Böylece SPI-1 kısa süreli, SPI-3 mevsimsel, SPI-6 orta vadeli ve SPI-12 uzun dönemli yağış koşullarını temsil edecek şekilde değerlendirilmiştir. SPI hesaplamalarında Gamma dağılımı ve olasılık ağırlıklı momentler yöntemi kullanılmış, dağılım parametreleri 1965–2025 döneminin tamamı esas alınarak belirlenmiştir. Sıfır yağış gözlenen aylar ise karma olasılık yaklaşımıyla değerlendirilmiştir (McKee vd., 1993).

Standartlaştırılmış Yağış ve Evapotranspirasyon İndisi (SPEI)

Kuraklığın değerlendirilmesinde yağış değişkenliğinin yanı sıra sıcaklık koşullarına bağlı atmosferik evaporatif talebin etkisini de dikkate almak amacıyla Standartlaştırılmış Yağış ve Evapotranspirasyon İndisi (SPEI) kullanılmıştır (Vicente-Serrano vd., 2010; Tirivarombo vd., 2018). SPEI hesaplamasının ilk aşamasında, aylık ortalama sıcaklık serileri kullanılarak Thornthwaite (1948) yöntemiyle aylık potansiyel evapotranspirasyon (PET) değerleri hesaplanmıştır. Hesaplamalarda istasyonun enlem bilgisi kullanılarak aylık gün uzunluğu ve ay süresine ilişkin düzeltmeler uygulanmıştır. Daha sonra aylık toplam yağıştan aylık PET değerleri çıkarılarak aylık iklimsel su dengesi: P – PET hesaplanmıştır. Elde edilen aylık su dengesi serisi kullanılarak SPEI-1, SPEI-3, SPEI-6 ve SPEI-12 değerleri hesaplanmıştır. SPEI hesaplamalarında üç parametreli log-Lojistik dağılım ve olasılık ağırlıklı momentler yöntemi kullanılmış, dağılım parametreleri 1965–2025 döneminin tamamı esas alınarak tahmin edilmiştir (Vicente-Serrano vd., 2010).

Kuraklık Sınıflandırması ve Kurak Dönem Analizi

Hesaplanan SPI ve SPEI değerleri standart kuraklık ve nemlilik sınıflarına göre değerlendirilmiştir (Tablo 1). Kuraklık olaylarının belirlenmesinde aylık SPI veya SPEI değerinin −1,00 ve altında olması kuraklık eşiği olarak kabul edilmiştir. Ardışık aylarda bu koşulun sağlandığı kesintisiz dönemler bir kuraklık olayı olarak tanımlanmıştır. Her olay için başlangıç ve bitiş tarihi ile olay süresi belirlenmiştir. Ortalama kuraklık süresi, tüm kuraklık olaylarının sürelerinin aritmetik ortalaması olarak hesaplanmıştır. Ortalama kuraklık şiddeti, kuraklık eşiğini sağlayan aylardaki SPI veya SPEI değerlerinin aritmetik ortalaması olarak belirlenmiştir. En uzun kuraklık olayı en fazla ardışık kurak ay içeren olay, en şiddetli kuraklık ise analiz dönemi boyunca gözlenen en düşük indis değeri olarak tanımlanmıştır.

Tablo 1. Standartlaştırılmış kuraklık indisleri (SPI/SPEI) sınıflandırma sistemi

İndeks değeri	Sınıf	Değerlendirme
≥ 2,00	Aşırı nemli	Çok yüksek derecede nemli koşullar
1,50 – 1,99	Çok nemli	Belirgin nemli koşullar
1,00 – 1,49	Orta nemli	Orta derecede nemli koşullar
−0,99 – 0,99	Normal	Normal / normale yakın koşullar
−1,00 – −1,49	Orta kurak	Orta şiddette kuraklık
−1,50 – −1,99	Şiddetli kurak	Şiddetli kuraklık koşulları
≤ −2,00	Aşırı kurak	Olağanüstü / aşırı kurak koşullar

SPI ve SPEI'nin Karşılaştırılması

SPI ve SPEI arasındaki ilişkinin belirlenmesi amacıyla aynı zaman ölçeklerine ait indis çiftleri karşılaştırılmıştır (Nwayor ve Robeson, 2023). İki indis arasındaki doğrusal ilişkinin gücü Pearson korelasyon katsayısı (r) ile değerlendirilmiştir. Ayrıca SPI değerlerinin SPEI değerlerini açıklama düzeyini belirlemek amacıyla doğrusal regresyon modelleri kurulmuş ve belirlilik katsayısı (R^2) hesaplanmıştır. Regresyon modelinin tahmin performansını değerlendirmek amacıyla Kök Ortalama Kare Hata (RMSE) ve Ortalama Mutlak Hata (MAE) ölçütleri kullanılmıştır (Soh vd., 2018; Poudel vd., 2024; Talebi vd., 2026). RMSE ve MAE, gözlenen SPEI değerleri ile regresyon modeli tarafından tahmin edilen SPEI değerleri arasındaki farklar üzerinden hesaplanmıştır. Analizler SPI/SPEI-1, SPI/SPEI-3, SPI/SPEI-6 ve SPI/SPEI-12 serileri için ayrı ayrı gerçekleştirilmiştir.

Mann–Kendall Trend Analizi

Sıcaklık, yağış, SPI ve SPEI serilerindeki uzun dönemli eğilimlerin belirlenmesinde parametrik olmayan Mann–Kendall (M-K) trend testi kullanılmıştır. Mann (1945) ve Kendall (1970) tarafından geliştirilen bu yöntem, hidroklimatolojik zaman serilerinde yaygın olarak kullanılmaktadır (Gocic ve Trajkovic, 2013; Agbo vd., 2023; Özdel ve Meydan, 2024; Özdel vd., 2025). Zaman serilerinde bulunabilecek seri otokorelasyonun M-K testinin varyansını ve buna bağlı olarak trend anlamlılığını etkileyebilmesi nedeniyle, bu çalışmada klasik M-K testi özgün seriye doğrudan uygulanmamıştır. Bunun yerine, otokorelasyonun etkisini azaltmak amacıyla Yue vd. (2002) tarafından önerilen Trend-Arındırılmış Ön-Beyazlatma (Trend-Free Pre-Whitening, TFPW) yaklaşımı kullanılmıştır. TFPW tabanlı Mann–Kendall testi, R ortamında modifiedmk paketinin tfpwmk() fonksiyonu kullanılarak uygulanmıştır. TFPW yaklaşımında trend bileşeni seriden ayrıştırılmakta, trendden arındırılmış seri üzerinden birinci dereceden otokorelasyon belirlenmekte, ön-beyazlatma işlemi gerçekleştirilmekte ve trend bileşeni yeniden eklenerek Mann–Kendall testi uygulanmaktadır (Yue vd., 2002).

İstatistiksel anlamlılık düzeyi $\alpha = 0.05$ ($Z = \pm 1.96$) olarak kabul edilmiştir. Buna göre $p < 0.05$ olması durumunda trend istatistiksel olarak anlamlı kabul edilmiş; trendin yönü ise test istatistiğinin işaretine göre belirlenmiştir. Pozitif değerler artış, negatif değerler ise azalış eğilimini göstermektedir. Trend analizinde zaman çözünürlükleri değişkenin niteliğine göre belirlenmiştir. Sıcaklık ve yağış değişkenlerinin trendleri yıllık seriler üzerinden değerlendirilmiştir. Bu kapsamda yıllık Tmean, Tmax ve Tmin değerleri ilgili yılın 12 aylık sıcaklık değerlerinin ortalaması, yıllık yağış ise 12 aylık toplam yağış değerlerinin toplamı alınarak elde edilmiştir. SPI ve SPEI indisleri ise aylık zaman çözünürlüğünde ve 1, 3, 6 ve 12 aylık ölçeklerde hesaplanmış; ancak uzun dönemli trend analizleri, her takvim yılındaki 12 aylık indis değerlerinin aritmetik ortalaması alınarak oluşturulan yıllık ortalama SPI ve SPEI serileri üzerinden gerçekleştirilmiştir. Dolayısıyla SPI ve SPEI için raporlanan

trend sonuçları aylık indislerin doğrudan trendini değil, yıllık ortalama indis değerlerindeki uzun dönemli değişimi ifade etmektedir.

Sen Eğim Tahmini

Mann–Kendall testi trendin yönü ve istatistiksel anlamlılığı hakkında bilgi sağlarken, trend büyüklüğünün belirlenmesi amacıyla Sen (1968) tarafından geliştirilen parametrik olmayan Sen eğim tahmini kullanılmıştır. Sen eğimi, zaman serisindeki tüm olası gözlem çiftleri arasındaki eğimlerin medyanı alınarak hesaplanmaktadır. Hesaplamalar R ortamında trend paketinin sens.slope() fonksiyonu kullanılarak gerçekleştirilmiştir. Sen eğimleri, M-K analizinde kullanılan yıllık seriler üzerinden hesaplanmıştır. Buna göre sıcaklık değişkenleri için eğim °C/yıl, yıllık toplam yağış için mm/yıl ve yıllık ortalama SPI/SPEI serileri için indis birimi/yıl olarak ifade edilmiştir. Pozitif Sen eğimi artış, negatif Sen eğimi ise azalış eğilimini göstermektedir. TFPW yaklaşımı trend anlamlılığının değerlendirilmesinde kullanılırken, trend büyüklüğünü ifade eden Sen eğimi orijinal yıllık seri üzerinden hesaplanmıştır.

İstatistiksel Değerlendirme ve Yazılım

Tüm veri işleme, aylık ve yıllık seri oluşturma, Thornthwaite PET hesaplaması, SPI ve SPEI hesaplamaları, kuraklık olay analizi, korelasyon ve regresyon analizleri ile trend analizleri R programlama ortamında gerçekleştirilmiştir. Veri işleme ve birleştirme işlemlerinde dplyr, Excel veri giriş ve çıktı işlemlerinde openxlsx, grafik üretiminde ggplot2, SPI ve SPEI ile Thornthwaite PET hesaplamalarında SPEI (Beguería vd., 2014) paketlerinden yararlanılmıştır. Trend-arındırılmış ön-beyazlatma (TFPW) tabanlı Modifiye Mann-Kendall test istatistiğinin (Z, p-değeri) hesaplanmasında modifiedmk (Patakamuri ve O'Brien, 2021), Sen eğim büyüklüğünün orijinal seri üzerinden tahmin edilmesinde ise trend (Pohlert, 2026) paketlerinden yararlanılmıştır. Zaman serisi grafiklerinde SPI ve SPEI değerleri aynı grafik üzerinde gösterilmiş; ayrıca farklı zaman ölçekleri için indisler arasındaki ilişki saçılım ve doğrusal regresyon grafikleri ile görselleştirilmiştir.

BULGULAR

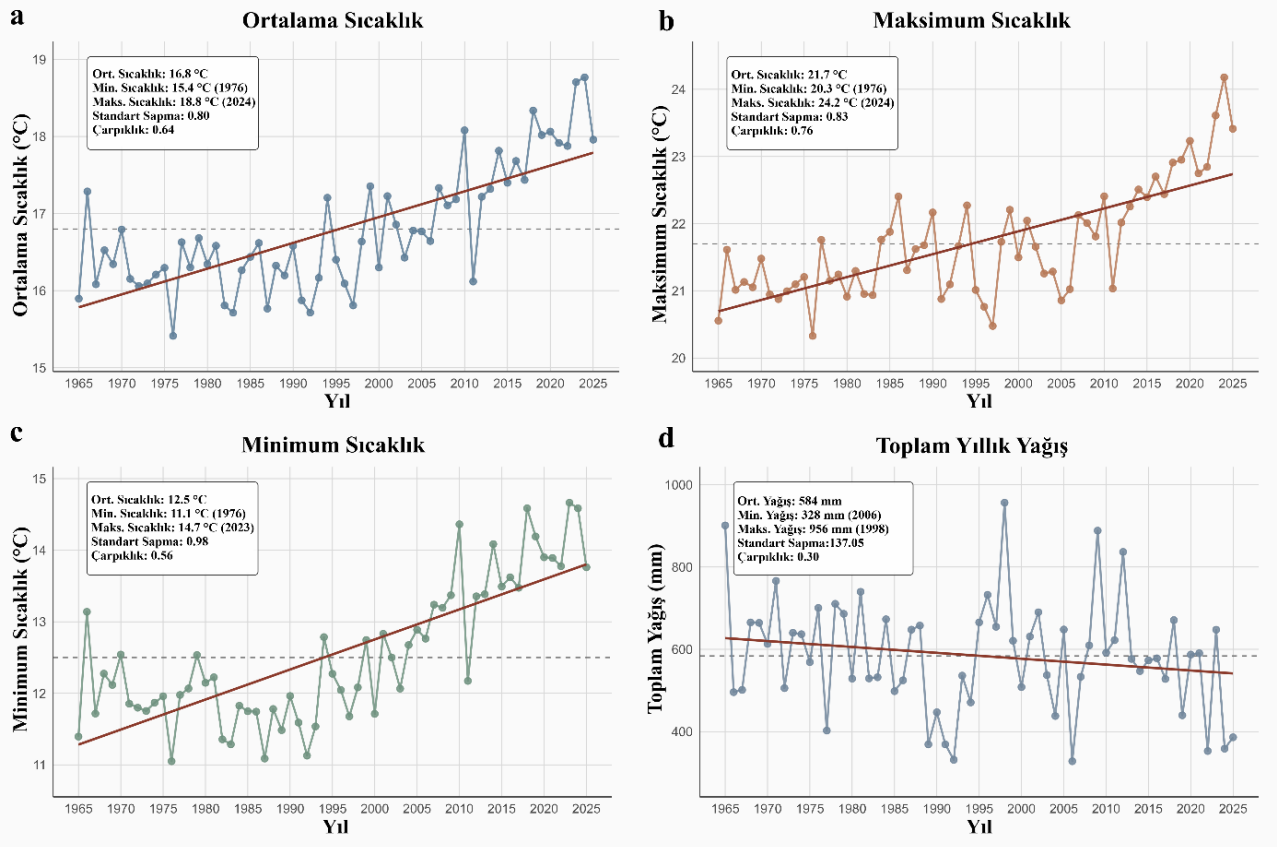
Sıcaklık ve Toplam Yıllık Yağışın Zamansal Değişimi

Dikili Meteoroloji İstasyonunun 1965–2025 dönemine ait sıcaklık ve toplam yıllık yağış serilerinin zamansal değişimi Şekil 2'de sunulmuştur. Yıllık ortalama sıcaklık serisinin dönem ortalaması 16,8 °C olup, en düşük değer 15,4 °C ile 1976 yılında, en yüksek değer ise 18,8 °C ile 2024 yılında kaydedilmiştir (Şekil 2a). Standart sapmanın 0,80 °C olması, yıllık ortalama sıcaklık değerlerindeki yıllar arası değişkenliğin düzeyini ortaya koymaktadır. Çarpıklık katsayısının 0,64 olması ise dağılımın yüksek sıcaklık değerleri yönünde daha uzun bir kuyruk sergilediğini ortaya koymaktadır. Zaman serisi boyunca yıllar arası dalgalanmalar görülmekle birlikte, özellikle 2000'li yıllardan sonra uzun dönem ortalamasının üzerinde kalan yılların daha sıklaştığı dikkat çekmektedir. Son yıllarda yüksek değerlerin yoğunlaşması, analiz döneminin son bölümünde yıllık ortalama sıcaklıkların önceki dönemlere göre daha yüksek düzeylerde gerçekleştiğini göstermektedir.

Maksimum sıcaklık serisinin dönem ortalaması 21,7 °C'dir. En düşük maksimum sıcaklık 20,3 °C ile 1976 yılında, en yüksek değer ise 24,2 °C ile 2024 yılında kaydedilmiştir (Şekil 2b). Standart sapmanın 0,83 °C olması, yıllık maksimum sıcaklık değerlerindeki yıllar arası değişkenliğin düzeyini ifade etmektedir. Çarpıklık katsayısının 0,76 olması, dağılımda yüksek maksimum sıcaklık değerlerinin daha uzun bir üst kuyruk oluşturduğunu göstermektedir. Zamansal dağılımda dönem boyunca dalgalanmalar devam etmekle birlikte, özellikle 2000'li yıllardan itibaren yüksek maksimum sıcaklıkların daha sık görülmesi ve 2024 yılında dönem maksimumunun gerçekleşmesi, serinin son bölümünde yüksek sıcaklık koşullarının belirginleştiğini göstermektedir.

Minimum sıcaklık serisinin dönem ortalaması 12,5 °C olup, en düşük değer 11,1 °C ile 1976 yılında, en yüksek değer ise 14,7 °C ile 2023 yılında kaydedilmiştir (Şekil 2c). Standart sapmanın 0,98 °C olması, yıllık minimum sıcaklık değerlerindeki yıllar arası değişkenliğin düzeyini ortaya koymakta ve üç sıcaklık değişkeni içerisinde en yüksek standart sapmanın minimum sıcaklık serisinde bulunduğunu göstermektedir. Çarpıklık katsayısı 0,56 olup, dağılımda yüksek minimum sıcaklık değerleri yönünde bir kuyruklanma görülmektedir. Zamansal değişim incelendiğinde, özellikle 2000'li yıllardan itibaren yüksek minimum sıcaklıkların daha sık ortaya çıktığı, son yıllarda ise bu değerlerin daha belirgin hale geldiği görülmektedir. En yüksek minimum sıcaklığın 2023 yılında gerçekleşmesi de serinin son bölümündeki yüksek sıcaklık koşullarını desteklemektedir.

Şekil 2. Sıcaklık ve toplam yıllık yağışın zamansal değişimi (a; ortalama sıcaklık, b; maksimum sıcaklık, c; minimum sıcaklık, d; yıllık toplam yağış)



Toplam yıllık yağış serisi, sıcaklık değişkenlerinden farklı olarak daha geniş bir yıllar arası değişkenlik göstermiştir (Şekil 2d). Dönem ortalaması 584 mm olan yıllık toplam yağış, 328 mm ile

2006 yılında en düşük, 956 mm ile 1998 yılında en yüksek değerine ulaşmıştır. Standart sapmanın 137,05 mm olması, yıllık yağış değerlerinin 584 mm'lik dönem ortalaması etrafında belirgin bir yıllar arası değişkenlik sergilediğini göstermektedir. Çarpıklık katsayısının 0,30 olması, yağış dağılımında yüksek yağış değerlerinin etkisiyle üst kuyruğun düşük yağış değerlerine göre bir miktar daha uzun olduğunu göstermektedir. Zaman serisinde yüksek ve düşük yağışlı yılların dönem boyunca birbirini izlemesi, yağış değişkenliğinin sürekliliğini ortaya koymaktadır. 1998 ve 2006 yıllarında kaydedilen sırasıyla 956 ve 328 mm'lik değerler, bu değişkenliğin en belirgin örneklerini oluşturmaktadır.

Genel olarak, Şekil 2'deki zaman serileri ve dağılım özellikleri birlikte değerlendirildiğinde, sıcaklık serilerinde analiz döneminin özellikle son bölümünde yüksek değerlerin daha sıklaştığı, yağış serisinde ise yıllar arası değişkenliğin belirgin biçimde devam ettiği görülmektedir. Ortalama, maksimum ve minimum sıcaklık serilerinde standart sapmalar sırasıyla 0,80, 0,83 ve 0,98 °C, toplam yıllık yağış serisinde ise 137,05 mm'dir. Bu tanımlayıcı istatistikler, serilerin değişkenlik ve dağılım özelliklerini ortaya koymakta; ancak uzun dönemli eğilimin istatistiksel anlamlılığı hakkında tek başına karar vermemektedir. Bu nedenle trendin yönü ve büyüklüğü sonraki bölümde Mann–Kendall testi ve Sen eğimi sonuçları üzerinden değerlendirilmiştir.

Sıcaklık ve Yağışların Trend Bulguları

Trend analizlerinde sıcaklık değişkenleri için yıllık ortalama değerler, yağış için ise yıllık toplam değerler kullanılmıştır. Yıllık ortalama sıcaklık serisinde TFPW Modifiye Mann–Kendall testi sonucunda Z = 6,180 ve Sen eğimi 0,034 °C/yıl olarak hesaplanmış ve istatistiksel olarak anlamlı pozitif yönlü trend belirlenmiştir. Maksimum sıcaklık için Z = 6,270 ve Sen eğimi 0,034 °C/yıl, minimum sıcaklık için ise Z = 6,576 ve Sen eğimi 0,042 °C/yıl olarak bulunmuştur. Her üç sıcaklık değişkenindeki trendin istatistiksel olarak anlamlı olması, analiz döneminde sıcaklık koşullarında ortak bir artış eğiliminin bulunduğunu göstermektedir. Sen eğiminin minimum sıcaklık için 0,042 °C/yıl ile diğer sıcaklık değişkenlerinden daha yüksek olması, minimum sıcaklık serisinin daha büyük pozitif trend eğimine sahip olduğunu göstermektedir.

Toplam yıllık yağış serisi için Mann–Kendall testi sonucunda Z = −1,091, Sen eğimi ise −1,486 mm/yıl olarak hesaplanmıştır. Sen eğiminin negatif yönde olmasına rağmen trend istatistiksel olarak anlamlı bulunmamıştır (Tablo 2). Dolayısıyla analiz döneminde toplam yıllık yağışta negatif yönlü bir eğilim işareti bulunmakla birlikte, bu eğilim istatistiksel olarak doğrulanmamıştır.

Tablo 2. Dikili Meteoroloji İstasyonunda sıcaklık ve yağış serilerinin Mann–Kendall ve Sen eğim analizi sonuçları

Parametreler	**TFPW M-K Z Skoru**	**Sen Slope (Yıl)**	**Trend**
Tmean	6,180	0,034	Anlamlı Artış
Tmax	6,270	0,034	Anlamlı Artış
Tmin	6,576	0,042	Anlamlı Artış
P	-1,091	-1,486	Anlamlı Trend Yok

Sıcaklık ve yağış trendleri birlikte değerlendirildiğinde, 1965–2025 döneminde sıcaklık değişkenlerinin tamamında anlamlı artış eğilimi bulunmasına karşılık, toplam yıllık yağış serisinde anlamlı bir trend belirlenmemiştir (Tablo 2). Bu sonuç, analiz dönemindeki iklimsel değişimin sıcaklık değişkenlerinde daha belirgin ve tutarlı bir yön taşıdığını, yıllık yağış toplamlarında ise aynı ölçüde sistematik bir değişimin bulunmadığını göstermektedir.

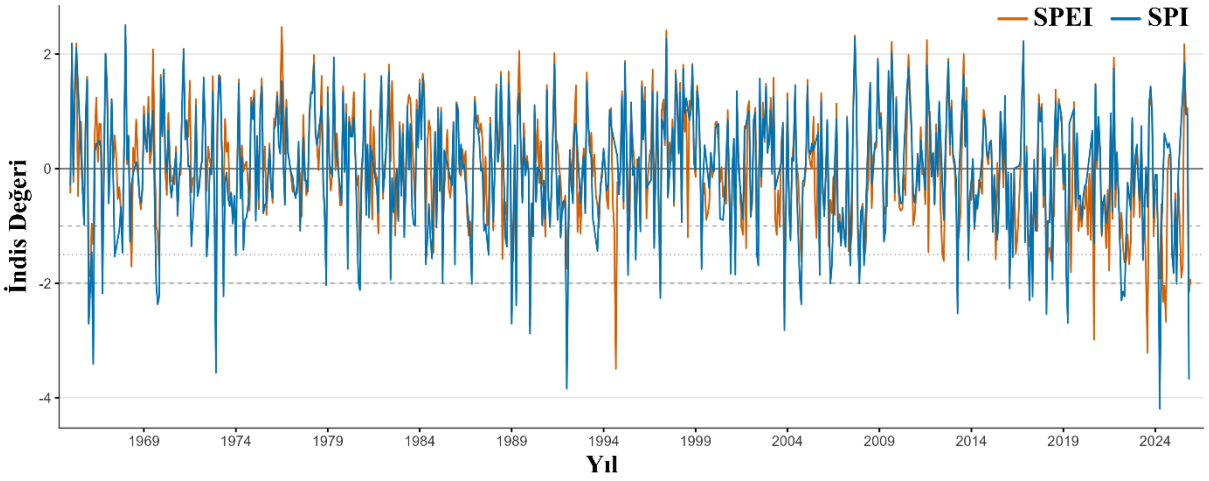
SPI ve SPEI Zaman Serilerinin Değişimi ve Trend Bulguları

SPI ve SPEI indisleri, 1965–2025 dönemindeki aylık yağış ve su dengesi koşullarını değerlendirmek amacıyla 1, 3, 6 ve 12 aylık zaman ölçeklerinde hesaplanmıştır. Şekil 3–6'da sunulan SPI ve SPEI serileri aylık zaman adımındaki indis değerlerini göstermektedir. Trend analizinde ise her yılın 12 aylık indis değerlerinin aritmetik ortalaması alınarak oluşturulan yıllık ortalama SPI ve SPEI serileri kullanılmıştır. Bu nedenle Tablo 3'te verilen Z ve Sen eğimleri, aylık indis serilerinin doğrudan trendini değil, yıllık ortalama indis serilerindeki uzun dönemli değişimi ifade etmektedir.

SPI ve SPEI serilerinin zamansal değişimi

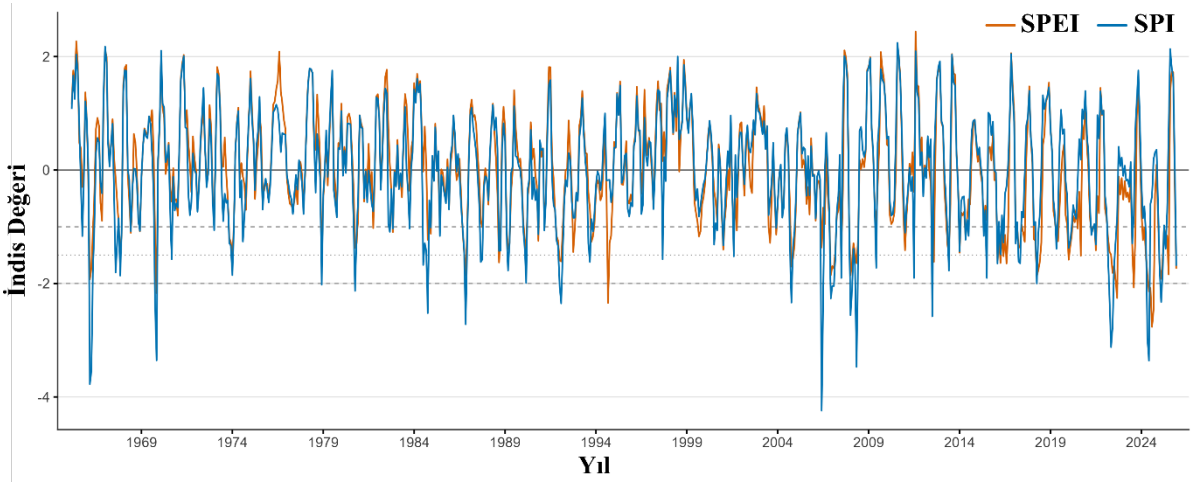
SPI-1 ve SPEI-1 serileri, bir aylık zaman ölçeğinin kısa dönemli hidroklimatik değişimlere duyarlılığına bağlı olarak yüksek frekanslı dalgalanmalar göstermiştir (Şekil 3). Her iki indis serisinde de negatif değerlerin farklı dönemlerde tekrarladığı ve kuraklık koşullarının analiz dönemi boyunca zamansal olarak değişkenlik gösterdiği görülmektedir. SPI-1 ile SPEI-1 genel olarak benzer zamansal örüntüler sergilemekle birlikte, bazı dönemlerde SPEI-1 değerlerinin SPI-1'e göre daha düşük seviyelere ulaştığı görülmektedir.

Şekil 3. Dikili Meteoroloji İstasyonunda SPI-1 ve SPEI-1 zaman serilerinin değişimi

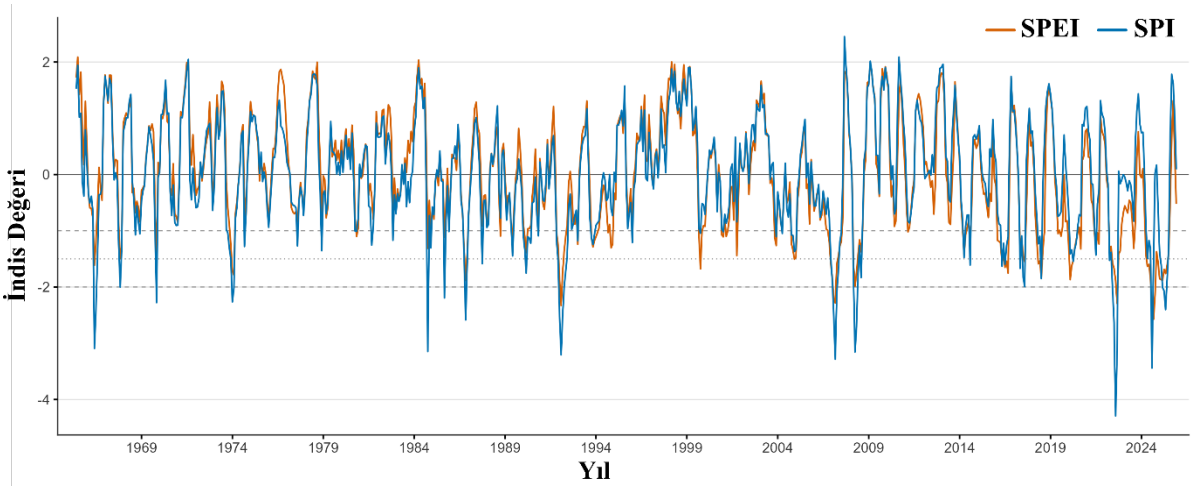


Üç aylık zaman ölçeğinde SPI-3 ve SPEI-3 serilerindeki kısa süreli dalgalanmaların bir aylık ölçeğe göre azaldığı ve kuraklık koşullarının daha süreklilik gösteren dönemler halinde ortaya çıktığı görülmektedir (Şekil 4). Altı aylık ölçekte bu süreklilik daha belirgin hale gelmiş ve negatif indis değerlerinin daha uzun süreli dönemler oluşturduğu gözlenmiştir (Şekil 5). On iki aylık ölçekte ise kısa süreli anomalilerin etkisi daha fazla dengelenmiş, buna karşılık uzun süreli kurak ve nemli dönemler daha belirgin hale gelmiştir (Şekil 6).

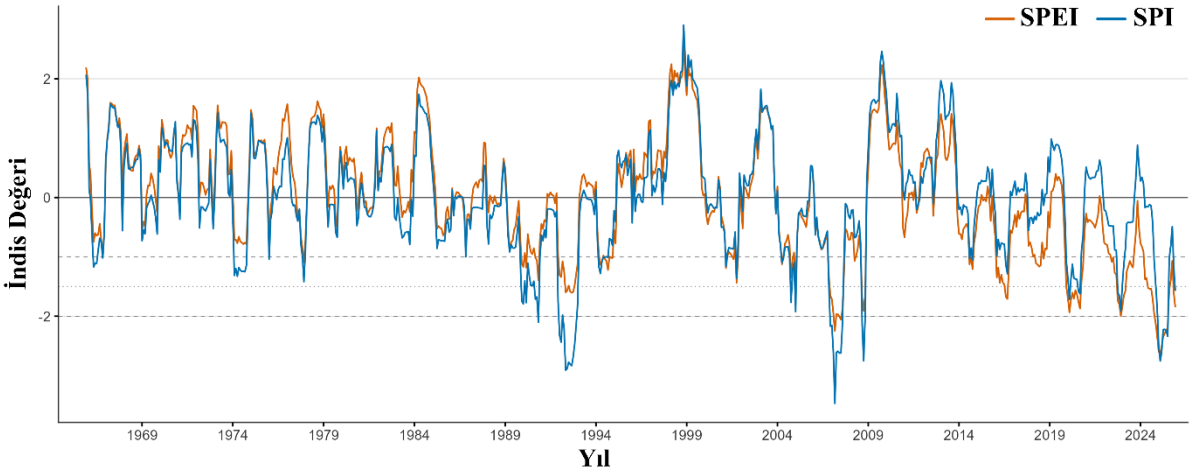
Şekil 4. Dikili Meteoroloji İstasyonunda SPI-3 ve SPEI-3 zaman serilerinin değişimi



Şekil 5. Dikili Meteoroloji İstasyonunda SPI-6 ve SPEI-6 zaman serilerinin değişimi



Şekil 6. Dikili Meteoroloji İstasyonunda SPI-12 ve SPEI-12 zaman serilerinin değişimi



Zaman ölçekleri arasındaki bu değişim, indis ölçeği büyüdükçe kısa süreli dalgalanmaların azalması ve kuraklık sinyalinin daha uzun süreli hidroklimatik koşulları temsil eden bir yapıya dönüşmesi şeklinde ortaya çıkmaktadır. Özellikle 12 aylık ölçekte indis değerlerinin daha yumuşak

bir zamansal değişim sergilemesi, uzun dönemli su açığı koşullarının daha belirgin şekilde izlenmesini sağlamıştır.

SPI ve SPEI Trendleri

SPI ve SPEI serilerinin trend sonuçları Tablo 3'te verilmiştir. SPI serilerinin tamamında Sen eğimi negatif yönde bulunmasına rağmen, hiçbir zaman ölçeğinde trend istatistiksel olarak anlamlı değildir. SPI-1 için Z = −0,179 ve Sen eğimi −0,011, SPI-3 için Z = −1,137 ve −0,003, SPI-6 için Z = −1,426 ve −0,005, SPI-12 için ise Z = −1,883 ve −0,011 olarak hesaplanmıştır (Tablo 3). SPEI serilerinde ise tüm zaman ölçeklerinde istatistiksel olarak anlamlı negatif yönlü trend belirlenmiştir. SPEI-1 için Z = −4,854 ve Sen eğimi −0,012; SPEI-3 için Z = −4,133 ve −0,012; SPEI-6 için Z = −3,662 ve −0,014; SPEI-12 için ise Z = −4,159 ve −0,028 olarak belirlenmiştir (Tablo 3). SPEI serilerindeki negatif yönlü eğilimler zaman ölçekleri arasında da farklı büyüklükler göstermektedir. Mutlak Sen eğimi açısından en yüksek değer SPEI-12'de (−0,028) elde edilirken, SPEI-1 serisi en yüksek mutlak Z değerini (−4,854) göstermiştir. Bu sonuçlar, uzun dönemli eğilimlerin değerlendirilmesinde yalnızca eğimin büyüklüğünün değil, eğilimin istatistiksel anlamlılığının da dikkate alınması gerektiğini göstermektedir.

Tablo 3. Dikili Meteoroloji İstasyonunda SPI ve SPEI serilerinin Mann–Kendall ve Sen eğim analizi sonuçları

Parametreler	TFPW M-K Z Skoru	Sen Slope	Trend
SPI-1	-0,179	-0,011	Anlamlı Trend Yok
SPEI-1	-4,854	-0,012	Anlamlı Azalış
SPI-3	-1,137	-0,003	Anlamlı Trend Yok
SPEI-3	-4,133	-0,012	Anlamlı Azalış
SPI-6	-1,426	-0,005	Anlamlı Trend Yok
SPEI-6	-3,662	-0,014	Anlamlı Azalış
SPI-12	-1,883	-0,011	Anlamlı Trend Yok
SPEI-12	-4,159	-0,028	Anlamlı Azalış

SPI ve SPEI sonuçları birlikte değerlendirildiğinde, aynı zaman ölçeklerinde iki indisin trend davranışlarının farklılaştığı görülmektedir. SPI serilerinde negatif yönlü ancak istatistiksel olarak anlamlı olmayan eğilimler belirlenirken, SPEI serilerinde 1, 3, 6 ve 12 aylık ölçeklerin tamamında anlamlı negatif trendler saptanmıştır (Tablo 3). Bu farklılık, iki indisin hidroklimatik koşullardaki değişimleri farklı bileşenler üzerinden temsil ettiğini ortaya koyan temel bulgulardan biridir.

Potansiyel Evapotranspirasyon (PET) ve Su Dengesi (P-PET) Eğilimleri

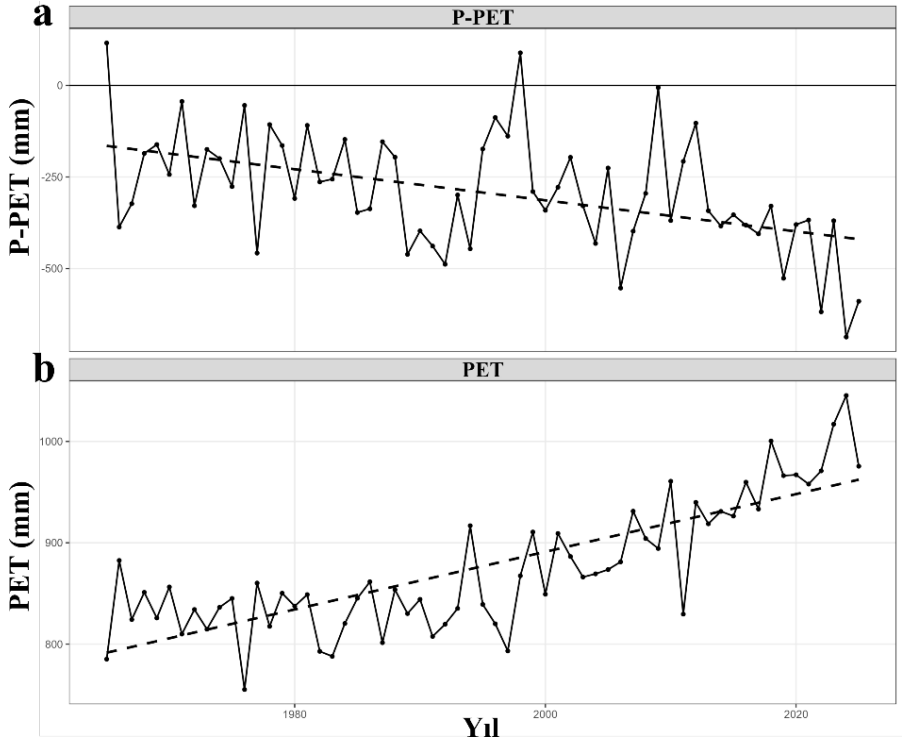
1965–2025 dönemine ait aylık ortalama sıcaklık ve yağış verileri kullanılarak Thornthwaite yöntemiyle aylık potansiyel evapotranspirasyon (PET) değerleri hesaplanmıştır. Aylık PET değerlerinin yıllık toplamları alınarak yıllık PET serisi, yıllık toplam yağış ile yıllık toplam PET arasındaki fark hesaplanarak da yıllık P-PET su dengesi serisi oluşturulmuştur. P-PET ve PET serilerine ilişkin zamansal değişimler Şekil 7'de, trend sonuçları ise Tablo 4'te sunulmuştur.

Yıllık P-PET serisi Şekil 7a'da sunulmuş olup, analiz dönemi boyunca belirgin yıllar arası dalgalanmalar sergilemekle birlikte, özellikle dönemin son bölümünde daha düşük değerlere yöneldiği görülmektedir. P-PET değerlerinin bazı yıllarda pozitif olduğu, ancak zaman içerisinde negatif değerlere doğru bir eğilimin belirginleştiği görülmektedir. P-PET serisi için TFPW Modifiye Mann–Kendall testi sonucunda Z = −3,438, Sen eğimi ise −4,247 mm/yıl olarak belirlenmiş ve istatistiksel olarak anlamlı azalış eğilimi saptanmıştır (Tablo 4). Yıllık toplam PET serisi ise Şekil 7b'de gösterilmiştir. PET değerleri analiz dönemi boyunca yıllar arasında değişkenlik göstermekle birlikte, özellikle dönemin son bölümünde daha yüksek değerlerin daha sık ortaya çıktığı görülmektedir. PET serisi için TFPW Modifiye Mann–Kendall testi sonucunda Z = 6,512 ve Sen eğimi +2,846 mm/yıl olarak bulunmuş; trendin pozitif yönlü ve istatistiksel olarak anlamlı olduğu belirlenmiştir (Tablo 4). P-PET ve PET serileri birlikte değerlendirildiğinde, analiz döneminde yıllık toplam PET'in anlamlı biçimde artmasına karşılık, yağış ile potansiyel evapotranspirasyon arasındaki yıllık farkı ifade eden P-PET serisinin anlamlı biçimde azaldığı görülmektedir (Tablo 4; Şekil 7). Bu iki eğilim birlikte, dönem boyunca evaporatif talepteki artış ile yıllık su dengesindeki değişimin aynı doğrultuda olmadığını ortaya koymaktadır.

Tablo 4. Dikili Meteoroloji İstasyonunda Potansiyel Evapotranspirasyon (PET) ve Su Dengesi (P-PET) serilerinin Mann–Kendall ve Sen eğim analizi sonuçları

Parametreler	**TFPW M-K Z Skoru**	**Sen Slope (Yıl)**	**Trend**
P-PET	-3,438	-4,247	Anlamlı Azalış
PET	6,512	2,846	Anlamlı Artış

Şekil 7. Dikili istasyonunda 1965–2025 döneminde yıllık PET ve P-PET değişimleri



Kuraklık Olaylarının Süre ve Şiddet Özellikleri

Kuraklık olayları, aylık SPI ve SPEI değerlerinin −1,00 veya daha düşük olduğu ardışık aylar esas alınarak belirlenmiş ve olayların frekans, süre ve şiddet özellikleri Tablo 5'te sunulmuştur. Kuraklık olaylarının belirlenmesinde indislerin aylık serileri kullanıldığından, burada verilen olay süreleri ardışık ay sayısını ifade etmektedir.

SPEI-1 serisinde toplam 88 kuraklık olayı belirlenmiş ve ortalama kuraklık süresi 1,38 ay olarak hesaplanmıştır. Ortalama kuraklık şiddeti −1,45 olurken, en uzun olay Nisan–Eylül 2022 döneminde 6 ay sürmüş ve en düşük SPEI-1 değeri −3,495 olarak Eylül 1994'te belirlenmiştir. SPI-1 serisinde ise 80 kuraklık olayı tespit edilmiş, ortalama süre 1,32 ay ve ortalama şiddet −1,76 olarak hesaplanmıştır. En uzun SPI-1 kuraklık olayı Şubat–Mayıs 2022 döneminde 4 ay sürerken, serinin en düşük değeri −4,194 ile Nisan 2024'te gerçekleşmiştir (Tablo 5).

Üç aylık ölçekte SPEI-3 serisinde 58, SPI-3 serisinde ise 66 kuraklık olayı belirlenmiştir. SPEI-3 olaylarının ortalama süresi 2,26 ay, ortalama şiddeti −1,42; SPI-3 olaylarının ortalama süresi ise 1,79 ay, ortalama şiddeti −1,67 olarak hesaplanmıştır. SPEI-3'te en uzun kuraklık olayı Şubat–Eylül 2016 döneminde 8 ay, SPI-3'te ise Ocak–Haziran 2008 döneminde 6 ay sürmüştür (Tablo 5).

Tablo 5. SPI ve SPEI serilerinde kurak dönemlerin süre ve şiddet özellikleri

İndis	Kurak Dönem Sayısı	Ortalama Kuraklık Süresi (Ay)	Ortalama Kuraklık Şiddeti	En Uzun Dönem Başlangıcı	En Uzun Dönem Bitişi	En Uzun Süre (Ay)	En Şiddetli Değer	En Şiddetli Tarih
SPEI-1	88	1,38	-1,45	04.2022	09.2022	6	-3,495	09.1994
SPI-1	80	1,32	-1,76	02.2022	05.2022	4	-4,194	04.2024
SPEI-3	58	2,26	-1,42	02.2016	09.2016	8	-2,76	08.2024
SPI-3	66	1,79	-1,67	01.2008	06.2008	6	-4,24	06.2006
SPEI-6	40	3,15	-1,43	04.2024	07.2025	16	-2,57	09.2024
SPI-6	42	2,64	-1,64	11.1991	06.1992	8	-4,29	08.2022
SPEI-12	24	4,75	-1,49	04.2024	12.2025	21	-2,62	02.2025
SPI-12	23	4,52	-1,68	11.1989	12.1990	14	-3,46	03.2007

Altı aylık ölçekte SPEI-6 için 40, SPI-6 için 42 kuraklık olayı belirlenmiştir. SPEI-6 olaylarında ortalama süre 3,15 ay, ortalama şiddet −1,43; SPI-6 olaylarında ise ortalama süre 2,64 ay, ortalama şiddet −1,64 olarak hesaplanmıştır. SPEI-6 serisindeki en uzun olay Nisan 2024–Temmuz 2025 döneminde 16 ay sürerken, SPI-6 serisinde en uzun olay Kasım 1991–Haziran 1992 döneminde 8 ay devam etmiştir (Tablo 5).

On iki aylık ölçekte kuraklık olaylarının sayısı daha da azalmış, buna karşılık ortalama olay süreleri artmıştır. SPEI-12 serisinde 24, SPI-12 serisinde 23 kuraklık olayı belirlenmiştir. Ortalama kuraklık süresi SPEI-12 için 4,75 ay, SPI-12 için 4,52 ay olarak hesaplanırken, ortalama şiddet değerleri sırasıyla −1,49 ve −1,68 olmuştur. SPEI-12 serisinde analiz dönemi içerisinde gözlenen en

uzun kesintisiz kurak dönem Nisan 2024–Aralık 2025 arasında 21 ay, SPI-12'de ise Kasım 1989–Aralık 1990 döneminde 14 ay sürmüştür (Tablo 5).

Kuraklık olaylarının zaman ölçekleri arasındaki dağılımı değerlendirildiğinde, ölçek büyüdükçe olay sayısının azalırken ortalama olay süresinin uzadığı görülmektedir. Bu örüntü, kısa zaman ölçeklerinde daha sık ancak kısa süreli kuraklık olaylarının, uzun zaman ölçeklerinde ise daha az sayıda fakat daha uzun süreli olayların öne çıktığını göstermektedir. SPI ve SPEI karşılaştırmasında ise SPEI serilerinde özellikle uzun zaman ölçeklerinde daha uzun süreli olayların belirginleştiği görülmektedir.

SPI ve SPEI Arasındaki İstatistiksel İlişki

SPI ve SPEI arasındaki ilişkinin zaman ölçeklerine göre değerlendirilmesi amacıyla Pearson korelasyon katsayısı, doğrusal regresyon, R^2, RMSE ve MAE değerleri hesaplanmış ve sonuçlar Tablo 6'da sunulmuştur. İki indis arasındaki ilişkinin görsel değerlendirmesi Şekil 8'de verilen saçılım ve regresyon grafikleri üzerinden gerçekleştirilmiştir.

SPI ve SPEI arasında tüm zaman ölçeklerinde güçlü ve pozitif yönlü ilişkiler belirlenmiştir. Pearson korelasyon katsayısı SPI-1/SPEI-1 için r = 0,877, SPI-3/SPEI-3 için r = 0,888, SPI-6/SPEI-6 için r = 0,922 ve SPI-12/SPEI-12 için r = 0,914 olarak hesaplanmıştır. Tüm ilişkiler istatistiksel olarak anlamlı bulunmuştur (Tablo 6).

Tablo 6. Farklı zaman ölçeklerinde SPI ve SPEI arasındaki istatistiksel ilişkinin değerlendirilmesi

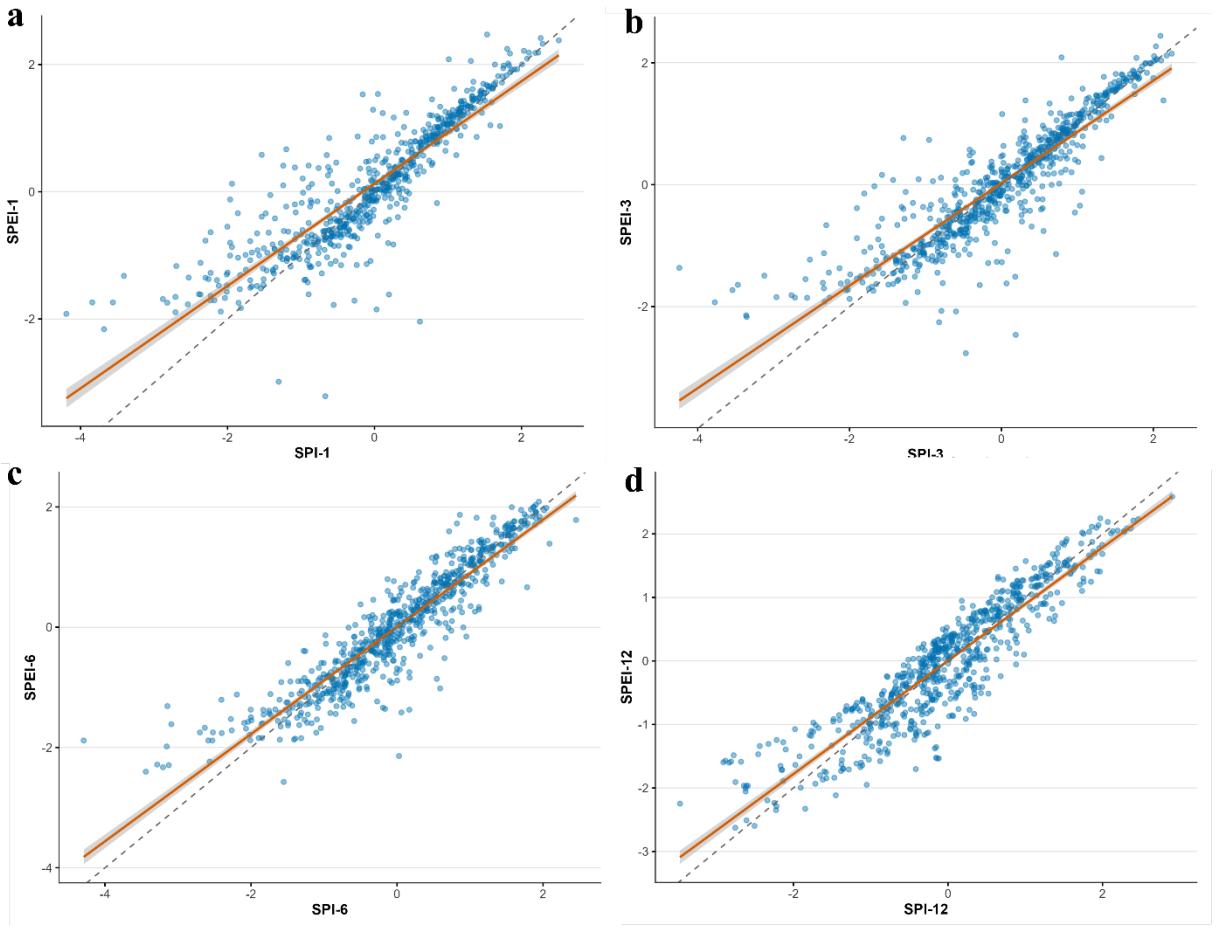
İndeks	Pearson korelasyon katsayısı (r)	p-değeri	Belirlilik katsayısı (R^2)	RMSE	MAE
SPI/SPEI-1	0,877	<0,001	0,770	0,472	0,334
SPI/SPEI-3	0,888	<0,001	0,790	0,453	0,315
SPI/SPEI-6	0,922	<0,001	0,850	0,383	0,277
SPI/SPEI-12	0,914	<0,001	0,835	0,400	0,320

Regresyon analizinde açıklanan varyans oranını gösteren R^2 değerleri sırasıyla SPI-1/SPEI-1 için 0,770, SPI-3/SPEI-3 için 0,790, SPI-6/SPEI-6 için 0,850 ve SPI-12/SPEI-12 için 0,835 olarak belirlenmiştir. Buna göre en yüksek açıklayıcılık SPI-6 ile SPEI-6 arasındaki ilişkide elde edilmiştir. Şekil 8'deki saçılım diyagramları da iki indis arasındaki güçlü doğrusal ilişkiyi desteklemektedir. Tahmin hatalarının değerlendirilmesinde RMSE değerleri SPI-1, SPI-3, SPI-6 ve SPI-12 için sırasıyla 0,472, 0,453, 0,383 ve 0,400 olarak hesaplanmıştır. MAE değerleri ise aynı ölçekler için sırasıyla 0,334, 0,315, 0,277 ve 0,320 olarak belirlenmiştir (Tablo 6). En düşük RMSE ve MAE değerlerinin SPI-6/SPEI-6 karşılaştırmasında elde edilmesi, regresyon modelinin bu zaman ölçeğinde SPEI değerlerini diğer ölçeklere kıyasla daha düşük hata ile tahmin ettiğini göstermektedir.

Genel olarak SPI ve SPEI arasındaki ilişkinin tüm zaman ölçeklerinde güçlü ve pozitif olması, iki indisin kurak ve nemli dönemlerin zamansal dağılımını büyük ölçüde benzer şekilde temsil ettiğini

göstermektedir. Bununla birlikte, korelasyon, açıklanan varyans ve hata ölçütlerinin zaman ölçeğine göre değişmesi, SPI ve SPEI arasındaki ilişkinin ölçekten bağımsız olmadığını ortaya koymaktadır (Tablo 6; Şekil 8).

Şekil 8. Dikili Meteoroloji İstasyonunda farklı zaman ölçeklerinde SPI ve SPEI değerleri arasındaki dağılım ve doğrusal ilişki: (a) SPI-1 ve SPEI-1, (b) SPI-3 ve SPEI-3, (c) SPI-6 ve SPEI-6 ve (d) SPI-12 ve SPEI-12.



Kuraklığın Potansiyel Ekolojik ve Çevresel Etkileri

Dikili Meteoroloji İstasyonu'na ait 1965–2025 dönemi bulguları, bölgedeki kuraklaşma sürecinin yalnızca yağış değişimleriyle açıklanamayacağını, sıcaklık artışı ve buna bağlı evaporatif talebin de dikkate alınması gerektiğini göstermektedir. Yıllık ortalama, maksimum ve minimum sıcaklıkların tamamında istatistiksel olarak anlamlı artış eğilimleri belirlenirken, toplam yıllık yağıştaki negatif yönlü eğilim anlamlı bulunmamıştır. Buna karşılık, potansiyel evapotranspirasyonda yıllık 2,846 mm artış ve P-PET su dengesinde yıllık 4,247 mm azalış belirlenmiştir. Bu sonuçlar, yağış toplamlarında anlamlı bir azalma bulunmasa bile atmosferik su talebinin yükseldiğini ve iklimsel su açığının zaman içerisinde büyüdüğünü göstermektedir.

SPI serilerinde bütün zaman ölçeklerindeki eğilimlerin negatif fakat istatistiksel olarak anlamsız olması, yağış eksikliğine dayalı kuraklaşmanın henüz belirgin ve sistematik bir uzun dönemli eğilim göstermediğine işaret etmektedir. Buna karşılık SPEI-1, SPEI-3, SPEI-6 ve SPEI-12 serilerinin tamamında anlamlı azalış eğilimlerinin saptanması, sıcaklık ve potansiyel

evapotranspirasyonun hesaba katılmasıyla kuraklaşma sinyalinin belirginleştiğini ortaya koymaktadır. Özellikle SPEI-12'de belirlenen −0,028'lik Sen eğimi, uzun dönemli su dengesi koşullarındaki bozulmanın daha güçlü olduğunu göstermektedir. Dolayısıyla Dikili'deki potansiyel ekolojik baskının yalnızca yağışların azalmasından değil, artan sıcaklıkların su kaybını hızlandırmasından kaynaklanabileceği düşünülmektedir.

Farklı zaman ölçeklerinde belirlenen kuraklıklar, ekosistemler açısından farklı süre ve nitelikte baskıları temsil edebilir. Bir ve üç aylık ölçeklerdeki kuraklıklar, kısa süreli su yetersizliği ve mevsimsel stres koşullarıyla ilişkilendirilebilir. Bu tür olayların özellikle bitkilerin büyüme ve gelişme dönemleriyle çakışması hâlinde doğal ve tarımsal bitki örtüsü üzerindeki su stresini artırma potansiyeli bulunmaktadır. Altı ve on iki aylık ölçeklerdeki kuraklıklar ise daha uzun süreli ve birikimli su açıklarını temsil ettiğinden toprak nemi, yüzey ve yeraltı suyu kaynakları ile suya bağımlı ekosistemler bakımından daha kalıcı bir baskı oluşturabilir.

Kuraklık olaylarının süre özellikleri de bu değerlendirmeyi desteklemektedir. SPEI-6 serisinde Nisan 2024–Temmuz 2025 arasında 16 ay, SPEI-12 serisinde ise Nisan 2024–Aralık 2025 arasında 21 ay devam eden kesintisiz kuraklıklar belirlenmiştir. Bu sürelerin aynı ölçeklerde SPI ile belirlenen en uzun kuraklıklardan daha fazla olması, sıcaklık ve evapotranspirasyonun dikkate alınmasıyla uzun süreli su açığının daha belirgin hâle geldiğini göstermektedir. Özellikle 2024–2025 döneminde farklı zaman ölçeklerinde eş zamanlı olarak belirlenen uzun süreli kuraklık koşulları, ekosistemlerin kurak dönemler arasında toparlanabilmesi için gereken sürenin azalmasına ve birikimli çevresel baskının artmasına yol açabilecek niteliktedir.

Minimum sıcaklıklardaki artış eğiminin yıllık 0,042 °C ile ortalama ve maksimum sıcaklıklardan daha yüksek olması da çevresel açıdan önemlidir. Bu bulgu, düşük sıcaklık koşullarının da zaman içerisinde yükseldiğini ve sıcaklık artışının yalnızca gündüz maksimumlarıyla sınırlı olmadığını göstermektedir. Böyle bir değişim, teorik olarak gece saatlerindeki serinleme ve nemlenme koşullarını sınırlandırarak su kayıplarının ve canlıların sıcaklık stresinin sürekliliğini artırabilir. Bununla birlikte, bu olası mekanizmanın Dikili ekosistemleri üzerindeki gerçek etkisinin belirlenebilmesi için günlük sıcaklıklar, bağıl nem, toprak nemi ve biyolojik göstergelerle desteklenen analizlere ihtiyaç bulunmaktadır.

SPI ile SPEI arasında bütün zaman ölçeklerinde güçlü ve pozitif ilişkiler bulunması, iki indisin kurak ve nemli dönemlerin genel zamanlamasını büyük ölçüde benzer biçimde yansıttığını göstermektedir. Buna rağmen SPI'de anlamlı bir eğilim bulunmazken SPEI'nin bütün ölçeklerde anlamlı azalış göstermesi, ekolojik ve çevresel değerlendirme bakımından temel bir farklılık oluşturmaktadır. Bu durum, yalnızca yağış verilerine dayalı değerlendirmenin sıcaklık artışından kaynaklanan ilave su açığını tam olarak yansıtmayabileceğini düşündürmektedir. Bu nedenle özellikle sıcaklıkların arttığı kıyı Akdeniz ortamlarında kuraklığın potansiyel ekolojik baskısını değerlendirmek için SPEI sonuçlarının SPI ile birlikte ele alınması önem taşımaktadır.

Kuraklaşmanın çevresel etkileri yalnızca yağış miktarındaki değişimlerle sınırlı olmayıp, toprak–bitki–su sistemi arasındaki ilişkilerin değişmesiyle birlikte değerlendirilmelidir. Özellikle sıcaklık ve potansiyel evapotranspirasyondaki artış, yağış miktarında istatistiksel olarak anlamlı bir azalma bulunmasa dahi, toprak yüzeyinden ve bitki örtüsünden gerçekleşen su kayıplarını artırarak ekosistemlerin kullanılabilir su miktarını azaltabilir. Bu durum, toprak neminin daha hızlı tükenmesine, bitkilerin su stresine daha erken girmesine ve özellikle yaz döneminde doğal ve tarımsal bitki örtüsünün kurak koşullara karşı duyarlılığının artmasına neden olabilecek bir iklimsel baskı oluşturmaktadır (Gouveia vd., 2017).

Dikili gibi Akdeniz ikliminin belirgin olduğu kıyı bölgelerinde uzun süreli su açığının yüzey ve yeraltı su kaynakları açısından da önemli sonuçları olabilir. Akdeniz ve Euro-Akdeniz bölgelerinde uzun süreli kuraklık ve artan iklimsel su açığının yeraltı su kaynakları üzerinde baskı oluşturabileceği ve bazı bölgelerde yeraltı su depolamasında azalma eğilimlerinin görüldüğü bildirilmektedir (Xanke ve Liesch, 2022). Yağışın yıllık toplamından bağımsız olarak artan evaporatif talep, yağışla sağlanan suyun toprakta tutulma süresini ve yeraltı suyunun beslenmesine katkısını sınırlandırabilir. Bu nedenle SPEI-6 ve özellikle SPEI-12 ölçeklerinde belirlenen uzun süreli kurak dönemler yalnızca meteorolojik bir kuraklık göstergesi olarak değil, su kaynaklarının yenilenme kapasitesi üzerinde oluşabilecek uzun süreli baskının bir göstergesi olarak da değerlendirilebilir. Bununla birlikte, bu ilişkinin doğrudan ortaya konulabilmesi için yeraltı su seviyesi, kaynak ve akım verileri ile toprak nemi ölçümlerinin birlikte değerlendirilmesi gerekmektedir.

Uzun süreli kuraklıkların ekosistemler üzerindeki önemli etkilerinden biri, kurak dönemler arasındaki toparlanma süresinin kısalması ve buna bağlı olarak su açığının birikimli bir baskıya dönüşmesidir. Özellikle SPEI-6 ve SPEI-12 serilerinde 2024–2025 döneminde belirlenen uzun süreli kuraklıklar, Dikili'de toplam yıllık yağıştan bağımsız olarak sıcaklık ve potansiyel evapotranspirasyon artışıyla güçlenen bir iklimsel su açığına işaret etmektedir. Bu süreç; doğal ve tarımsal bitki örtüsünde su stresinin artması, toprak neminin azalması, su kaynaklarının beslenmesinin zayıflaması ve suya bağımlı sulak alanlar ile diğer habitatların kırılganlığının artması gibi potansiyel çevresel sonuçlar doğurabilir. Ancak bu çalışmada biyolojik çeşitlilik, vejetasyon değişimi, toprak nemi, yüzey suyu veya sulak alan dinamikleri doğrudan analiz edilmediğinden, söz konusu etkiler kanıtlanmış ekolojik değişimler olarak değil, belirlenen iklimsel kuraklaşmanın ve buna bağlı su açığının potansiyel çevresel baskıları olarak değerlendirilmelidir.

Bu açıdan değerlendirildiğinde, meteorolojik kuraklık indislerinin çevresel izleme verileriyle birlikte ele alınması, bölgesel kuraklık değerlendirmelerinin etkinliğini artıracaktır. Gelecekte SPI ve SPEI serilerinin uydu tabanlı vejetasyon indisleri (NDVI/EVI), toprak nemi, yüzey suyu alanları, yeraltı su seviyeleri ve tarımsal üretim verileriyle birlikte değerlendirilmesi, iklimsel su açığının ekosistemler üzerindeki gerçek karşılığının ortaya konulmasına olanak sağlayacaktır (AghaKouchak vd., 2015; Vicente-Serrano vd., 2013). Böyle bir bütünleşik yaklaşım, yalnızca kuraklığın başlangıç

ve şiddetinin belirlenmesini değil, aynı zamanda kuraklığın çevresel sistemlerde hangi aşamada ölçülebilir bir etkiye dönüştüğünün de izlenmesini mümkün kılacaktır.

SONUÇ VE ÖNERİLER

Bu çalışmada, Dikili Meteoroloji İstasyonu'nun 1965–2025 dönemine ait sıcaklık ve yağış verileri kullanılarak kuraklığın uzun dönemli değişimi SPI ve SPEI indisleri üzerinden değerlendirilmiştir. Analizler 1, 3, 6 ve 12 aylık zaman ölçeklerinde gerçekleştirilmiş; iklim değişkenlerindeki eğilimler TFPW Modifiye Mann–Kendall testi ve Sen eğimi yöntemiyle incelenmiştir. Ayrıca potansiyel evapotranspirasyon ve iklimsel su dengesi eğilimleri belirlenerek SPI ile SPEI sonuçları karşılaştırılmıştır.

Çalışmanın en belirgin sonucu, Dikili'deki uzun dönemli iklimsel değişimin yağıştan çok sıcaklık ve evaporatif talep üzerinden gerçekleşmesidir. Yıllık ortalama, maksimum ve minimum sıcaklıkların tamamında istatistiksel olarak anlamlı artış eğilimleri saptanmıştır. Ortalama ve maksimum sıcaklıkların her ikisinde Sen eğimi 0,034 °C/yıl, minimum sıcaklıkta ise 0,042 °C/yıl olarak hesaplanmıştır. Minimum sıcaklıklardaki artış eğiminin diğer sıcaklık değişkenlerinden daha yüksek olması, bölgedeki ısınmanın yalnızca gündüz maksimumlarıyla sınırlı kalmadığını, düşük sıcaklık koşullarının da belirgin biçimde değiştiğini göstermektedir.

Toplam yıllık yağışta −1,486 mm/yıl büyüklüğünde negatif bir eğilim belirlenmesine rağmen bu eğilim istatistiksel olarak anlamlı değildir. Ayrıca yağış serisinde yüksek ve düşük yağışlı yılların birbirini izlemesi, Dikili'de yağışların belirgin bir yıllar arası değişkenlik gösterdiğini ortaya koymuştur. Buna karşılık yıllık potansiyel evapotranspirasyonda 2,846 mm/yıl düzeyinde anlamlı artış, P-PET ile ifade edilen iklimsel su dengesinde ise 4,247 mm/yıl düzeyinde anlamlı azalış belirlenmiştir. Bu bulgular, toplam yıllık yağış belirgin biçimde azalmasa bile artan sıcaklık ve evaporatif talep nedeniyle iklimsel açıdan kullanılabilir su miktarının azalabileceğini göstermektedir. SPI ve SPEI sonuçları arasındaki farklılık da bu değerlendirmeyi desteklemektedir. SPI-1, SPI-3, SPI-6 ve SPI-12 serilerinin tamamında negatif yönlü eğilimler görülmüş, ancak bu eğilimlerin hiçbiri istatistiksel olarak anlamlı bulunmamıştır. Buna karşılık SPEI'nin bütün zaman ölçeklerinde anlamlı azalış eğilimi gösterdiği belirlenmiştir. En yüksek mutlak Sen eğiminin SPEI-12 serisinde −0,028 olarak hesaplanması, sıcaklık ve potansiyel evapotranspirasyonun etkisinin özellikle uzun dönemli su açığı koşullarında belirginleştiğini ortaya koymaktadır. Bu nedenle yalnızca yağış verisine dayanan SPI, sıcaklık artışının kuraklık üzerindeki güçlendirici etkisini tek başına yeterince yansıtmayabilir. İki indis arasında bütün zaman ölçeklerinde güçlü ve istatistiksel olarak anlamlı pozitif ilişkiler bulunmuştur. Pearson korelasyon katsayılarının 0,877 ile 0,922 arasında değişmesi, SPI ve SPEI'nin kurak ve nemli dönemlerin genel zamanlamasını büyük ölçüde benzer şekilde temsil ettiğini göstermektedir. En güçlü ilişki SPI-6 ile SPEI-6 arasında belirlenmiştir. Bununla birlikte, güçlü korelasyona rağmen iki indisin uzun dönemli eğilimlerinin farklılaşması, benzer zamanlarda kuraklık belirlemelerinin değişimin kaynağı ve büyüklüğü konusunda aynı sonucu vermek zorunda olmadığını

göstermektedir. Başka bir ifadeyle, SPI ve SPEI benzer kurak dönemleri gösterebilmekte; ancak SPEI, artan sıcaklık ve evapotranspirasyonun su dengesi üzerindeki etkisini daha belirgin biçimde yansıtabilmektedir.

Kuraklık olaylarının süre ve frekans özellikleri, kullanılan zaman ölçeğine bağlı olarak değişmiştir. Kısa zaman ölçeklerinde daha fazla sayıda ancak daha kısa süreli kuraklıklar belirlenirken, zaman ölçeği büyüdükçe olay sayısı azalmış ve ortalama kuraklık süresi uzamıştır. SPEI serilerinde, özellikle uzun zaman ölçeklerinde, SPI'ye göre daha uzun süreli kuraklıkların öne çıktığı görülmüştür. SPEI-6 serisinde Nisan 2024–Temmuz 2025 arasında 16 ay ve SPEI-12 serisinde Nisan 2024–Aralık 2025 arasında 21 ay devam eden kesintisiz kuraklıkların belirlenmesi, son dönemde birikimli su açığı koşullarının dikkat çekici düzeye ulaştığını göstermektedir.

Bulgular ekolojik ve çevresel açıdan değerlendirildiğinde, Dikili'de belirlenen kuraklaşmanın temelinde yalnızca yağış yetersizliğinin değil, artan sıcaklıklar ve yükselen atmosferik su talebinin de bulunduğu anlaşılmaktadır. PET'teki anlamlı artış ve P-PET'teki anlamlı azalış; toprakta ve su kaynaklarında tutulabilecek suyun azalması, bitki su stresinin artması ve suya bağımlı doğal ve tarımsal sistemlerin iklimsel baskıya daha açık hâle gelmesi bakımından önem taşımaktadır. Özellikle uzun süreli SPEI kuraklıkları, ekosistemlerin kurak dönemler arasındaki toparlanma olanaklarını azaltabilecek ve birikimli çevresel baskıyı artırabilecek niteliktedir.

Bu nedenle Dikili'de kuraklık yönetiminin yalnızca su arzı ve tarımsal sulama açısından değil; toprak neminin korunması, doğal bitki örtüsünün sürekliliği, suya bağımlı habitatların dayanıklılığı ve ekosistemlerin uzun süreli iklimsel su açığına uyum kapasitesi açısından da ele alınması gerekmektedir.

Bununla birlikte, çalışmada doğrudan ekolojik göstergeler kullanılmadığından bu sonuçlar gerçekleşmiş ekolojik değişimlerin kanıtı olarak değil, meteorolojik bulguların işaret ettiği potansiyel ekolojik ve çevresel baskılar olarak yorumlanmalıdır.

Sonuç olarak Dikili'de kuraklığın izlenmesinde yalnızca yağış değişkenine dayalı yaklaşımların yeterli olmayabileceği anlaşılmıştır. SPI meteorolojik yağış eksikliğini belirlemede yararlı olmakla birlikte, SPEI'nin sıcaklık ve potansiyel evapotranspirasyon etkisini de içermesi, günümüzdeki ısınma koşullarında kuraklığın daha kapsamlı değerlendirilmesini sağlamaktadır. Bu nedenle bölgedeki kuraklık izleme ve su kaynakları planlama çalışmalarında SPI ve SPEI'nin birlikte kullanılması önerilmektedir.

Elde edilen bulgular doğrultusunda aşağıdaki öneriler geliştirilmiştir:

- Kuraklık izleme çalışmalarında yağış miktarının yanı sıra sıcaklık, potansiyel evapotranspirasyon ve P-PET su dengesi göstergeleri de düzenli olarak değerlendirilmelidir.
- Kısa süreli meteorolojik ve tarımsal etkilerin izlenmesinde 1 ve 3 aylık; mevsimsel ve birikimli su açığının değerlendirilmesinde 6 ve 12 aylık SPI ve SPEI serileri birlikte kullanılmalıdır.

- SPEI'de bütün zaman ölçeklerinde belirlenen anlamlı azalış eğilimleri, kuraklık yönetimi ve su kaynakları planlamasında sıcaklık kaynaklı su kayıplarının özellikle dikkate alınması gerektiğini göstermektedir.
- Uzun süreli SPEI kuraklıklarının tarımsal sulama talebi, toprak suyu, yüzey ve yeraltı suyu kaynakları üzerindeki potansiyel etkileri göz önünde bulundurularak su kullanımında mevsimsel ve çok yıllı planlama yaklaşımları geliştirilmelidir.
- Özellikle 2024–2025 döneminde belirlenen uzun süreli kuraklıkların benzeri olaylara karşı erken uyarı ve izleme sistemleri güçlendirilmelidir. İzleme sistemlerinde tek bir kuraklık indisi yerine yağış, sıcaklık, evapotranspirasyon ve su dengesi göstergelerini bir araya getiren bütünleşik bir yaklaşım benimsenmelidir.
- Dikili ve çevresindeki doğal ve tarımsal alanların iklimsel su açığına karşı duyarlılığı dikkate alınarak su tasarrufu, sulama verimliliği ve kurak dönemlere uyum önlemleri yerel planlama süreçlerine dâhil edilmelidir.
- Gelecekte yapılacak çalışmalarda SPI ve SPEI sonuçlarının toprak nemi, yeraltı suyu seviyesi, akım, rezervuar doluluk oranı, bitki örtüsü indisleri ve tarımsal verim gibi göstergelerle karşılaştırılması önerilmektedir. Böylece bu çalışmada teorik olarak değerlendirilen potansiyel ekolojik etkiler doğrudan sınanabilir.
- Thornthwaite yöntemiyle hesaplanan PET sıcaklığı temel alan bir yaklaşım olduğundan, yeterli meteorolojik veri bulunması durumunda sonuçların Penman–Monteith gibi radyasyon, nem ve rüzgâr değişkenlerini de dikkate alan yöntemlerle karşılaştırılması yararlı olacaktır.

Bu çalışma, Dikili'de yağış eğiliminden bağımsız olarak sıcaklık ve evaporatif talep artışıyla güçlenen bir kuraklaşma sürecinin bulunduğunu ortaya koymaktadır. Bu yönüyle çalışma, kuraklığın yalnızca "yağış azlığı" biçiminde ele alınmaması; iklimsel su dengesi ve potansiyel ekolojik baskılarla birlikte değerlendirilmesi gerektiğini göstermektedir.

KAYNAKÇA

Agbo, E. P., Nkajoe, U., & Edet, C. O. (2023). Comparison of Mann–Kendall and Şen's innovative trend method for climatic parameters over Nigeria's climatic zones. *Climate Dynamics*, 60(11), 3385-3401. https://doi.org/10.1007/s00382-022-06521-9

AghaKouchak, A., Farahmand, A., Melton, F. S., Teixeira, J., Anderson, M. C., Wardlow, B. D., & Hain, C. R. (2015). Remote sensing of drought: Progress, challenges and opportunities. Reviews of Geophysics, 53(2), 452–480. https://doi.org/10.1002/2014RG000456

Bacanlı, Ü. G. (2017). Trend analysis of precipitation and drought in the Aegean region, Turkey. *Meteorological Applications,* 24(2), 239–249. https://doi.org/10.1002/met.1622

Beguería, S., Vicente-Serrano, S. M., Reig, F., & Latorre, B. (2014). Standardized precipitation evapotranspiration index (SPEI) revisited: parameter fitting, evapotranspiration models, tools, datasets and drought monitoring. International journal of climatology, 34(10), 3001-3023. https://doi.org/10.1002/joc.3887

Danandeh Mehr, A., Sorman, A. U., Kahya, E. & Afshar, M. H. (2020). Climate change impacts on meteorological drought using SPI and SPEI: Case study of Ankara, Turkey. *Hydrological Sciences Journal, 65*(2), 254–268. https://doi.org/10.1080/02626667.2019.1691218

Eriş, E., Çavuş, Y., Aksoy, H., Burgan, H. İ., Aksu, H. & Boyacıoğlu, H. (2020). Spatiotemporal analysis of meteorological drought over Küçük Menderes River Basin in the Aegean Region of Turkey. *Theoretical and Applied Climatology,* 142, 1515–1530. https://doi.org/10.1007/s00704-020-03384-0

Erlat, E., & Güler, H. (2023). Türkiye'de standardize yağış evapotranspirasyon indisine (SPEI) göre kuraklıkların zamansal değişimi (1951–2022). *Ege Coğrafya Dergisi, 32*(Cumhuriyet'in 100. Yılı Özel Sayısı), 77–90. https://doi.org/10.51800/ecd.1332424

Gocic, M., & Trajkovic, S. (2013). Analysis of precipitation and drought data in Serbia over the period 1980–2010. *Journal of Hydrology*, 494, 32-42. https://doi.org/10.1016/j.jhydrol.2013.04.044

Gouveia, C. M., Trigo, R. M., Beguería, S., & Vicente-Serrano, S. M. (2017). Drought impacts on vegetation activity in the Mediterranean region: An assessment using remote sensing data and multi-scale drought indicators. Global and Planetary Change, 151, 15–27. https://doi.org/10.1016/j.gloplacha.2016.06.011

Gümüş, V. (2023). Evaluating the effect of the SPI and SPEI methods on drought monitoring over Turkey. *Journal of Hydrology,* 626, 130386. https://doi.org/10.1016/j.jhydrol.2023.130386

IPCC, (2022). *Climate change 2022: Impacts, adaptation and vulnerability*. Cambridge University Press. https://www.ipcc.ch/report/ar6/wg2/

Kayan, O., & Erlat, E. (2024). Ege Bölgesi'nde standardize yağış evapotranspirasyon indisi (SPEI) ile kuraklık değerlendirmesi (1951–2022). *Ege Üniversitesi Ziraat Fakültesi Dergisi, 61*(2), 249–258. https://doi.org/10.20289/zfdergi.1412233

Kendall, M. G. (1970). *Rank correlation methods* (4th ed.). London: Charles Griffin.

Kömüşcü, A. Ü. (1999). Using the SPI to analyze spatial and temporal patterns of drought occurrence in Turkey. *Drought Network News,* 11(1), 7–13. https://digitalcommons.unl.edu/droughtnetnews/49?utm_source=digitalcommons.unl.edu%2Fdroughtnetnews%2F49&utm_medium=PDF&utm_campaign=PDFCoverPages

Mann, H. B. (1945). Nonparametric tests against trend. *Econometric*a, 13(3), 245-259. https://doi.org/10.2307/1907187

McKee, T. B., Doesken, N. J., & Kleist, J. (1993, January). The relationship of drought frequency and duration to time scales. In *Proceedings of the 8th Conference on Applied Climatology* (Vol. 17, No. 22, pp. 179-184).

Mersin, D., Gülmez, A., Safari, M. J. S., Vaheddoost, B. & Tayfur, G. (2022). Drought assessment in the Aegean Region of Turkey. *Pure and Applied Geophysics,* 179, 3035–3053. https://doi.org/10.1007/s00024-022-03089-7

Nwayor, I. J. & Robeson, S. M. (2024). Exploring the relationship between SPI and SPEI in a warming world. *Theoretical and Applied Climatology,* 155, 2559–2569. https://doi.org/10.1007/s00704-023-04764-y

Öz, F. Y., Özelkan, E. & Tatlı, H. (2024). Comparative analysis of SPI, SPEI, and RDI indices for assessing spatio-temporal variation of drought in Türkiye. *Earth Science Informatics*, 17, 4473-4505. https://doi.org/10.1007/s12145-024-01401-8

Özdel, M. M., & Meydan, A. (2024). Diyarbakır Havzası yöresinde 1964-2023 dönemi sıcaklıklarında gözlenen değişim ve eğilimler. *Memba Kastamonu Üniversitesi Su Ürünleri Fakültesi Dergisi*, 10(2), 29-42. https://doi.org/10.58626/menba.1496870

Özdel, M. M., Durak, M., Aykır, D., & Kızılçaoğlu, A. (2025). Effects of Climate Change on Balıkesir Province: Investigation of Temperature Extremes for the Period 1975-2023. *Journal of Geography*, (51), 107-122. https://doi.org/10.26650/JGEOG2025-1681760

Pamuk, G., Özgürel, M., & Topçuoğlu, K. (2004). Standart yağış indisi (SPI) ile Ege Bölgesinde kuraklık analizi. *Ege Üniversitesi Ziraat Fakültesi Dergisi, 41*(1), 99–106.

Patakamuri, S. K., ve O'Brien, N. (2021) ModifiedM-K: Modified Mann Kendall Trend Tests. R paketi. https://cran.r-project.org/web/packages/modifiedmk/index.html

Pohlert, T. (2026). Trend: Non-Parametric Trend Tests and Change-Point Detection. R Paketi. https://cran.r-project.org/web/packages/trend/index.html

Poudel, B., Dahal, D., Banjara, M., & Kalra, A. (2024). Assessing meteorological drought patterns and forecasting accuracy with SPI and SPEI using machine learning models. *Forecasting*, 6(4), 1026-1044. https://doi.org/10.3390/forecast6040051

Sen, P. K. (1968). Estimates of the regression coefficient based on Kendall's tau. Journal of the American statistical association, 63(324), 1379-1389.

Soh, Y. W., Koo, C. H., Huang, Y. F., & Fung, K. F. (2018). Application of artificial intelligence models for the prediction of standardized precipitation evapotranspiration index (SPEI) at Langat River Basin, Malaysia. *Computers and electronics in agriculture*, 144, 164-173. https://doi.org/10.1016/j.compag.2017.12.002

Talebi, H., Citakoglu, H., Samadianfard, S., & Erol, A. (2026). Advanced Hybrid Machine Learning for Precise Short-Term Drought Prediction: A Comparative Study of SPI and SPEI Indices in Iran's Arid and Semi-Arid Regions. *Pure and Applied Geophysics*, 183(2), 793-819. https://doi.org/10.1007/s00024-025-03876-y

Tanrıkulu, A., Guner , U., & Bahar, E. (2024). The Assessment of Precipitation and Droughts in the Aegean Region Using Stochastic Time Series and Standardized Precipitation Index. *Atmosphere,* 15(8), 1001. https://doi.org/10.3390/atmos15081001

Tefera, A. S., Ayoade, J. O. & Bello, N. J. (2019). Comparative analyses of SPI and SPEI as drought assessment tools in Tigray Region, Northern Ethiopia. *SN Applied Sciences,* 1, 1265. https://doi.org/10.1007/s42452-019-1326-2

Thornthwaite, C. W. (1948). An approach toward a rational classification of climate. Geographical review, 38(1), 55-94.

Tirivarombo, S., Osupile, D. & Eliasson, P. (2018). Drought monitoring and analysis: Standardised Precipitation Evapotranspiration Index (SPEI) and Standardised Precipitation Index (SPI). *Physics and Chemistry of the Earth,* 106, 1–10. https://doi.org/10.1016/j.pce.2018.07.001

Vicente-Serrano, S. M., Beguería, S. & López-Moreno, J. I. (2010). A multiscalar drought index sensitive to global warming: The Standardized Precipitation Evapotranspiration Index. *Journal of Climate,* 23(7), 1696–1718. https://doi.org/10.1175/2009JCLI2909.1

Vicente-Serrano, S. M., Gouveia, C., Camarero, J. J., Beguería, S., Trigo, R., López-Moreno, J. I., Azorín-Molina, C., Pasho, E., Lorenzo-Lacruz, J., Revuelto, J., Morán-Tejeda, E., & Sanchez-Lorenzo, A. (2013). Response of vegetation to drought time-scales across global land biomes. *Proceedings of the National Academy of Sciences,* 110(1), 52–57. https://doi.org/10.1073/pnas.1207068110

Xanke, J., & Liesch, T. (2022). Quantification and possible causes of declining groundwater resources in the Euro-Mediterranean region from 2003 to 2020. *Hydrogeology Journal,* 30, 379–400. https://doi.org/10.1007/s10040-021-02448-3

Yue S, Pilon P, Phinney B, Cavadias G. 2002. The influence of correlation on the ability to detect trend in hydrological series. *Hydrological Processes* 16,1807–1829. https://doi.org/10.1002/hyp.1095


BİDGE