

COĞRAFİ YAPAY ZEKA TEKNİKLERİ İLE AKDENİZ HAVZASINDA POTANSİYEL DENİZ ÇAYIRI ALANLARININ BELİRLENMESİ

Identification of Potential Seagrass Areas in the Mediterranean Basin Using Geospatial
Artificial Intelligence (GeoAI) Techniques

Şevki DANACIOĞLU¹

Selim Mirsat GÜL²

Berkay BALLI³

Öz

Günümüzde canlılık küresel iklim değişikliği ve artan çevre sorunlarına bağlı, birçok sorunla karşı karşıyadır. Denizlerin akciğerleri olarak da isimlendirilen deniz çayırları ekosistem için çok önemli yere sahiptir. Güneş ışınlarının ulaştığı sığ sularda bulunan deniz çayırları, oksijen üretim kapasitesine sahip oldukları için denizlerin akciğerleri konumundadır. Deniz çayırları ayrıca deniz canlıları için yaşam ortamı sağlamakta ve otla beslenen canlıların besin kaynağını oluşturmaktadır. Bu araştırma Akdeniz'deki deniz çayırlarının habitat alanlarının coğrafi yapay zeka teknikleriyle tahmin edilmesini amaçlamaktadır. Potansiyel deniz çayırları alanlarının belirlenmesinde Coğrafi Yapay Zeka (GeoAI) teknikleri kullanılmıştır. Buna göre geliştirilen yapay zeka modeli ile araştırma alanında türün var olduğu bölgelerin koşullarını dikkate alarak bir habitat dağılım modeli oluşturulması hedeflenmektedir. Bu bağlamda çalışmada deniz çayırlarının habitat koşullarını etkileyen 7 mekânsal değişken belirlenmiştir. Araştırmada Copernicus Deniz İzleme Servisi tarafından sağlanan 2023 yılına ait veri setleri kullanılmıştır. Ayrıca aynı kaynak tarafından sağlanan mevcut deniz çayırlarına ait veriler yapay zeka modelinin eğitilmesi amacıyla kullanılmıştır. Araştırmada ArcGIS Pro 3.2 yazılımı içerisinde yer alan ve Maksimum Entropi yöntemine göre türlerin var olma olasılığını tahmin etmek için kullanılan Presence-only Prediction (MaxEnt) aracı kullanılmıştır. Buna göre modelde kesme değeri (Cutoff) 0,5 olarak belirlenmiş ve bu bağlamda sınıflandırılma sonuçlarına göre model tahmininde %67.7'lik bir doğruluk elde edilmiştir. Elde edilen sonuç haritasında belirgin bir şekilde yüksek olasılık değerlerine sahip olan bölgeler Türkiye güneyinde İskenderun Körfezi, Ege Denizinin Doğu ve Batı kıyıları ile Güney kesimleri, Güney Levanten Denizinde Mısır kıyıları, Orta ve Kuzey Adriyatik Denizi kıyıları, Sicilya Güneyi ile birlikte özellikle Tunus Kıyıları ve Batı Akdeniz'de İspanya'nın Doğu-Güneydoğu kıyıları deniz çayırları habitatlarının yaygın olarak bulunduğu alanları işaret etmektedir. Sonuçlar, coğrafi yapay zeka tekniklerinin, ekosistem tahmininde, karasal veya denizel habitatların belirlenmesinde etkili şekilde kullanılabileceğini göstermektedir. Çalışma bulgularının, habitatların dağılımını belirleme ve koruma çabalarını yönlendirme potansiyeline sahip olduğu düşünülmektedir.

Anahtar kelimeler: Akdeniz Havzası, Coğrafi Yapay Zekâ, GeoAI, Habitat İzleme, Maksimum Entropi.

Abstract

In today's world, biodiversity faces many challenges due to global climate change and increasing environmental problems. Seagrass meadows, also referred to as the lungs of the sea, play a crucial role in ecosystems. Seagrasses found in shallow waters reached by sunlight are considered the lungs of the sea due to their capacity to produce oxygen. Additionally, seagrass meadows provide habitats for marine organisms and serve as a food source for grazers. This research aims to predict the habitat areas of seagrass meadows in the

¹ İzmir Bakırçay Üniversitesi, İnsan ve Toplum Bilimleri Fakültesi, Coğrafya Bölümü, İzmir-Türkiye, sevki.danacioglu@bakircay.edu.tr, <https://orcid.org/0000-0003-1118-352X>

² Sorumlu Yazar/Corresponding Author: İzmir Bakırçay Üniversitesi, İnsan ve Toplum Bilimleri Fakültesi, Coğrafya Bölümü, İzmir-Türkiye, mirsatgul@gmail.com, <https://orcid.org/0009-0004-6195-0947>

³ İzmir Bakırçay Üniversitesi, İnsan ve Toplum Bilimleri Fakültesi, Coğrafya Bölümü, İzmir-Türkiye, bberkay.balli@gmail.com, <https://orcid.org/0009-0006-7352-3904>

Mediterranean using geospatial artificial intelligence (GeoAI) techniques. GeoAI techniques were employed to determine potential seagrass areas. An artificial intelligence model was developed to create a habitat distribution model considering the conditions of regions where the species exists within the study area. Seven spatial variables influencing the habitat conditions of seagrasses were identified in this study. Data sets from the Copernicus Marine

Monitoring Service for the year 2023 were utilized. Data on existing seagrass meadows from the same source were used to train the artificial intelligence model. Within the ArcGIS Pro 3.2 software, the Presence-only Prediction (MaxEnt) tool was employed to predict the probability of species presence according to the Maximum Entropy method. The cutoff value in the model was set to 0.5, resulting in a 67.7% accuracy in model prediction based on classification results. The resulting map shows areas with significantly high probability values, indicating widespread seagrass habitat presence. These areas include the southern coast of Turkey, the Gulf of Iskenderun, the eastern and western coasts of the Aegean Sea, the southern parts of the Eastern Mediterranean Sea, the coasts of Egypt in the Levantine Sea, the coasts of the Central and Northern Adriatic Sea, the southern part of Sicily, especially the coasts of Tunisia, and the eastern-southeastern coasts of Spain in the Western Mediterranean. The results demonstrate that geospatial artificial intelligence techniques can effectively be used to predict ecosystems and identify terrestrial or marine habitats. The findings of this study are believed to have the potential to guide efforts in determining the distribution and conservation of habitats.

Keywords: Geospatial Artificial Intelligence, GeoAI, Habitat Monitoring, Maximum Entropy, Mediterranean Basin.

GİRİŞ

Beşerî faktörler, iklim değişiklikleri, çevre sorunları canlıların yaşam alanlarına olumsuz yönde etki etmektedir (Costanza, 1997: 256). Deniz çayırları denizel ekosistemler için büyük öneme sahiptir ve denizlerin neredeyse %1'lik bir kısmını kapsamalarına rağmen tüm dünyanın kıyı bölgelerinde (Antartika kıyıları hariç) gözlemlenmektedir (Dural vd, 2013: 46). Sığ bölgelerde yer almasından dolayı güneş ışığı ile fotosentez yaparak ormanlardan sonra oksijen üreten en büyük kaynaklardan biridir ve ürettikleri yüksek seviyede oksijen ile denizlerin akciğeri olarak adlandırılırlar (Short vd., 1996: 19). Deniz çayırları, denizde çiçek açan bitkilerden oluşan değerli bir bitki topluluğudur ve bu bitki grubu besin filtrasyonu ve besin çeşitliliği sağlamasından dolayı yüzgeçli balıklar ve kabuklu deniz ürünlerine ev sahipliği yapmaktadır (Short vd., 1996: 17). Kökleri deniz tabanına bağlanır ve su altında oluşacak erozyonları önler (Boudouresque & Meinesz, 1982: 160; Cirik & Cirik, 1999).

Dünya üzerinde yaşayan her bir canlının uygun yaşam alanlarına ihtiyacı vardır. Bütün canlılar kendi yaşam koşullarına uygun doğal alanlarda yaşamaktadır. İnsanoğlu ise bu yaşam koşullarını anlamlandırabilmek için canlıları takip etmektedir. Bu bağlamda, insanoğlu çeşitli yöntem ve teknolojilerden yararlanarak habitatların izlenmesi ve takibine yönelik sistematik araştırmalar gerçekleştirmektedir. Bu araştırmalar sürecinde birden fazla materyalden yararlanılmaktadır. Yaşam alanlarını hava, kara ve su olarak ele alacak olursak yaşayan her canlı için farklı bir izleme yöntemi öne çıkmaktadır. Kablosuz sensörler, foto kapanlar, GPS cihazları, uydu ölçümleri bu amaçla yaygın biçimde tercih edilmektedir (Lahoz-Monfort vd., 2021" ve Mainwaring vd., 2002: 89). Bütün bu mekânsal bilgilerin işlenebilmesi ve analizi için araç olarak da çeşitli coğrafi bilgi sistemleri ve uzaktan algılama programları yöntemleri kullanılmaktadır.

Uzaktan algılama ve Coğrafi Bilgi Sistemlerinin yaygınlaşması, uydu verileri sayesinde araziye çıkmadan yapılan analizleri kolaylaştırmış ve doğruluğunu artırmıştır. Uydu görüntüleri, kullanım alanlarına göre arazi çalışmalarının zorluğunu ortadan kaldırıp, yapılan arazi çalışmaların daha kolay ve daha doğru olma olasılığını yükseltmiştir. Dünya üzerinde arazi çalışması yapılamayacak alanların dahi incelenmesine olanak sağlamaktadır. Ekosistemlerin keşifleri deniz tabanlarına yapılan dalışlarla olmaktadır. Ancak bu zahmetli hem de maliyetli bir yol olmuştur. Analizler için kullanılacak olan verilerin ve bu veri setlerinin değerlendirilmesi için coğrafi bilgi sistemi ve uzaktan algılama süreçleri etkili bir şekilde kullanılmaktadır. Çok kriterli karar verme yöntemi coğrafi analiz gerektiren akademik çalışmaların büyük bir bölümünde kullanılmaktadır. Habitat üzerinde incelenecek olan bölgelerin kesin ve net sınırları belirli olmadığı için yapılan bu analizde çok kriterli karar verme metodu kullanılmamıştır. Bu yöntem dışında tahmin sağlayan farklı yöntemler bulunmaktadır.

Günümüzde artan yapay zekâ kullanımı, uzaktan algılama ve coğrafi bilgi sistemlerine de entegre olmuş durumdadır. 21. Yüzyılın sansasyonel olaylarından biri olan yapay zekâ hayatımızı kolaylaştıran en büyük materyallerden biri konumuna gelmiştir. Coğrafi bilgi sistemleri de yapılan araştırmaları ve çalışmaları kolaylaştırmak için bir araç olarak kullanılmasından dolayı yapay zekâ da bu sektöre uyum sağlamış durumdadır. Coğrafi Yapay Zekâ (GeoAI) ulaşılması ve hakkında tahminde bulunulması zor olan coğrafi alanların anlamlandırılmasında kullanılmaktadır.

Bu araştırma da Akdeniz'deki deniz çayırlarının habitat alanlarının Coğrafi Yapay Zekâ (GeoAI) teknikleriyle tahmin edilmesini amaçlamaktadır

MATERYAL VE YÖNTEM

Çalışma Alanı

Çalışma alanı Akdeniz Havzası'nın, Ege Denizi, Levant Denizi, İyon Denizi, Adriyatik Denizi, Tiren Denizi ile Akdeniz'in batı, doğu ve merkez kısımlarını kapsamaktadır (Şekil 1). Havza genelinde tipik akdeniz iklimi gözlemlenmektedir. Bu iklim türünde yazları sıcak ve kurak, kışları ise ılık ve yağışlı geçmektedir. En derin nokta, batimetri verilerinden alınan bilgiler ile -5117 metre olarak gözlemlenmiştir.

Deniz çayırlarının dünyada 0,12 milyon km² ile 0,6 milyon km² arasında alan kapladığı tahmin edilmektedir (Duarte vd., 1999: 163). Akdeniz Havzası'nda 5 tür deniz çayır alanı bulunmaktadır. Bunlar; Posidonia oceanica, Cymodocea nodosa (Ucria) Ascherson, Zostera noltii Hornemann, Zostera marina Linnaeus ve Halophila stipulacea (Forsk.) Ascherson (Akçalı, Karayalı, 2021: 102). 40 metre derinliğe kadar olan kumlu deniz tabanı üzerinde gelişen deniz çayırları, bölgedeki oksijen miktarını arttırmaktadır ve bu sebepten dolayı Akdeniz'de bulunan denizel ekosistemin %20'sine habitat sağlamaktadır. Yapılan literatür taramalarında Akdeniz sahillerinde yaklaşık 50.000 km²'lik bir alan kapladığı; sadece Fransa kıyılarında 1150 km²'lik bir alanda yayılım gösterdiği tahmin edilmektedir (Pasqualini vd., 1997: 1168).



Şekil 1. Çalışma alanı konum haritası

Veri

Deniz çayırlarıyla ilgili birçok çalışma bulunmasına rağmen kesin referans koşulları hala net olarak bilinmemektedir (Vaachi vd., 2014). Coğrafi yapay zekâ modeli geliştirilmek için mevcut deniz çayırı alanları ile belirlenen 7 adet mekânsal veri işleme sokulacaktır. Mekânsal veriler Copernicus Deniz İzleme Servisi tarafından sağlanmıştır. Sığ su alanları batimetri verilerinden kesilerek elde edilmiştir. Mevcut deniz çayır alanları, World Ocean Database tarafından üretilen veri seti kullanılarak elde edilmiştir. Çalışmada kullanılan bütün veriler tablo 1'de gösterilmiştir. Ayrıca mevcut deniz çayır alanları ve mekânsal verilerin alansal dağılımları Şekil 2'de verilmiştir.


Tablo 1. Araştırmada Kullanılan Veri Kaynakları

Veriler	Çözünürlük	Tür	Birim	Yıl	Kaynak
Nitrat	4.7 km ²	Raster	[mmol/m ³]	2020	Copernicus Deniz İzleme Servisi (CMEMS)
Fosfat	4.7 km ²	Raster	[mmol/m ³]	2020	Copernicus Deniz İzleme Servisi (CMEMS)
Tuzluluk	4.7 km ²	Raster	[10-3]	2020	Copernicus Deniz İzleme Servisi (CMEMS)
Batimetri	4.7 km ²	Raster	Metre (m)	2020	Avrupa Deniz Gözlem Ve Veri Ağı (EMODNET)
Silikat	4.7 km ²	Raster	[mmol/m ³]	2020	Copernicus Deniz İzleme Servisi (CMEMS)
Sıcaklık	4.7 km ²	Raster	[°C]	2020	Copernicus Deniz İzleme Servisi (CMEMS)
Oksijen	4.7 km ²	Raster	[mmol/m ³]	2020	Copernicus Deniz İzleme Servisi (CMEMS)
Mevcut alanlar	-	Vektör	.shp	2021	Word Ocean Database
Sığ bölgeler	4.7 km ²	Raster	Metre (m)	2020	Avrupa Deniz Gözlem Ve Veri Ağı (EMODNET)



Şekil 2. Akdeniz Havzasındaki deniz çayır alanları


Mekânsal verilerin dağılışı incelendiğinde batimetri değerlerinin kıyı bölgelerden uzaklaştıkça arttığı gözlemlenmiştir. Fosfat, Silikat, Tuzluluk ve Nitrat değerleri, Akdeniz Havzası'nın batıdan doğuya doğru gidildikçe arttığı belirlenmiştir. Mekansal verilerin dağılışı İtalya'nın batı kıyılarından başlayarak batıya doğru Tiren Denizi, Ligurian Denizi, İspanya kıyılarına yer alan Balear Denizi ve Cebelitarık Boğazına kadar olan Alboran Denizi'ni kapsamaktadır. Oksijen verisi artış trendi diğer veriler ile aynı özelliktedir. Fakat Türkiye kıyılarında yer alan Akdeniz, Levanten Denizi, İskenderun Körfezi, Antalya Körfezi'nde değerlerin düşük olduğu gözlemlenmektedir. Sıcaklık verisi enlem etkisinden dolayı ekvatorial bölgelere yaklaştıkça artmaktadır. Tunus, Libya, Mısır, İsrail ve Suriye kıyılarında sıcaklık artış gözlemlenmiştir (Şekil 3).



Şekil 3. Çalışmada kullanılan veri setlerinin mekânsal dağılımı

Yöntem


Deniz çayır alanlarının tahmin sürecinde ArcGIS Pro 3.2 yazılımı içerisinde yer alan Presence-only Prediction (MaxEnt) aracı kullanılmıştır. İş akış şeması Şekil 4'te verilmiştir. Bu araç Maksimum Entropi (MaxEnt) yöntemini kullanmaktadır. MaxEnt, belirli bir dizi kısıtlama altında bir olasılık dağılımını en geniş dağılım olarak tanımlayan bir bilgi teoreti prensibidir (De Martino & De Martino, 2018). Türlerin oluşum modellerini rastgele oluşturulmuş arka plan verilerini kullanarak tahmin etme amacı ile kullanılan deterministik bir yöntemdir (Elith vd., 2011). Hem kategorik hem de sürekli verilerin bağımlı değişken olarak kullanılabilirdiği MaxEnt yöntemi, ekoloji (Elith vd., 2011), sağlık (Du vd., 2014), afet yönetimi (Mobley vd., 2019), istatistik (Fithian vd., 2013) gibi alanlarda, mevcut fenomenlerin olasılıklarının tahmininde yaygın biçimde kullanılmaktadır. Buna göre araştırmanın analiz süreci Şekil 5'te verilmiştir.



Şekil 4. İş akış şeması

GeoAI tahmin modelinin oluşturulmasında, CMEMS (Copernicus Deniz İzleme Servisi) tarafından sağlanan mekânsal veriler ve WOD'den (World Ocean Database) elde edilen mevcut veriler analizde değişken olarak kullanılmıştır. İlk olarak CMEMS tarafından elde edilen raster verilerin ölçekleri 21.72 km² olarak indirilmiştir. Ölçeklendirme işlemi uygulanarak bütün raster veriler 4.7 km² çözünürlüğe dönüştürülmüştür. Dönüşüm sağlanan verileri enterpolasyon işlemine sokabilmek için her bir pikselin değerleri Raster To Point aracı ile nokta veri haline getirilmiştir. İnterpolasyon yöntemi olarak IDW (Inverse Distance Weight) tercih edilmiş ve mekânsal çözünürlükler bu işlem sırasında 2

km²'ye düşürülmüştür. Diğer yandan mevcut deniz çayır noktalarına işlem yapılamadığı için noktalar etrafına 5 km çapında alan oluşturulmuş ve servis tarafından sağlanan alan verileri ile birleştirilmiştir. Birleştirilen veri setlerine rastgele 5000 adet nokta oluşturulmuştur. Bu işlem model eğitim sırasında mevcut deniz çayır alanlarının ölçüm değerlerini alabilmesini sağlamaktadır. Presence-only Prediction (MaxEnt) aracı eğitim için interpolasyon işlemi sonucu oluşan raster veriler ve oluşturulan 5000 adet eğitim noktasına göre işlem yapmaktadır.



Şekil 5. Analiz akış diyagramı

Model eğitim sırasında değiştirilmesi gereken birçok parametre içermektedir. Bu çalışmada seçilen parametreler gösterilmiştir (Tablo 2). Parametrelerde seçilen Number Of Knot değeri 10 olarak belirlenmiştir. Bu değer açıklanacak değişkenlerin belirli fonksiyonlarla genişletilmesinde kullanılan düğüm sayısını ifade etmektedir. Kesme değeri (Cutoff) 0,5 olarak işleme alınmıştır. Bu değer altında kalan bölümleri yokluk (0,4-0,3-0,2-0,1), üstünde kalan değerleri (0,6-0,7-0,8-0,9) ise varlık olarak algılamasına olanak sağlamaktadır.

Tablo 2. Model Parametreleri


Açıklayıcı Değişken Genişletmeleri (Temel Fonksiyonlar) (Explanatory Variable Expansions (Basis Functions))	Orijinal (Doğrusal), Eşli Etkileşim (Çarpım), Yumuşatılmış Adım (Hinge) (Original (Linear), Pairwise Interaction (Product), Smooth step (Hinge))
Düğüm Sayısı (Number Of Knots)	10
Çalışma Alanı (Study Area)	Dışbükey Kapsama (Convex Hull)
Mekansal Seyreltme En Yakın Komşu Mesafesi (Spatial Thinning Minimum Neighbor Distance)	2 km
Varlık- Arka Plan Görelî Ağırlığı (Relative Weight of Presence to Background)	100

Varlık Olasılığı Dönüşümü (Bağlantı Fonksiyonu) (Presence Probability Transformation (Link Function))	c-log-log
Varlık Olasılığı Eşik Değeri (Presence Probability CutOff)	0,5000

Değer aralığı 0,01 ile 0,99 arasındadır. Düşük kesme değeri modelin daha fazla tahmin yapmasına ve daha az sayıda yanlış negatif sonuç üretmesine neden olabilir, ancak bu durum yanlış negatiflerin artmasına yol açabilmektedir. Yüksek bir kesme değeri modelin daha kesin olmasına ve yanlış pozitiflerin artmasına neden olabilir, ancak bu durum yanlış negatiflerin artmasına sebep olmaktadır. Yanlış negatif durumu, gerçekte pozitif olan ancak model tarafından negatif olarak sınıflandırılan durumları ifade etmektedir. Yanlış pozitif ise gerçekte negatif olan ancak model tarafından pozitif olarak sınıflandırılan durumları ifade eder. Bu terimler sınıflandırma modellerinin doğruluğunu ve performansını değerlendirmek için kullanılan önemli metriklerdir.


BULGULAR

Eğitimi tamamlanan yapay zekâ modelinin elde ettiği sonuçlar kapsamında modelin eğitim sürecinde kendi ürettiği birkaç parametre vardır. Şekil 6’da gösterildiği üzere, Presence-only Prediction (MaxEnt) aracının çıktılarından olasılık değerlerini belirli aralıklara bölen bir sayımı temsil eder. Diğer yandan Varlık Noktaları ile Arka Plan noktaları olasılık aralıklarını belirlemektedir. Bu bilgi, modelin belirli olasılık aralıklarında ne kadar doğru tahmin yaptığını anlamak için kullanılabilir. Bu olasılık aralıklarında, model tarafından tahmin edilen varlık (presence) ve arka plan (background) noktalarının sayısı ayrı ayrı hesaplanmıştır (Şekil 6). Belirli bir aralıkta yüksek sayıda varlık tahmini ve düşük sayıda arka plan tahmini, modelin bu aralıkta iyi performans gösterdiğini gösterebilir. Ancak, yanlış negatif (varlığı göz ardı etme) veya yanlış pozitif (yanlış varlık tahmini) durumlarına dikkat etmek önemlidir.



Şekil 6. Arka plan ve Varlık noktalarının olasılık aralıkları

Presence-only Prediction (MaxEnt) aracı arka planda ürettiği varlık noktalarını ve bu noktaların olasılık tahminlerini Distribution of Probability of Presence by Classifications (Varlık Olasılığının Dağılımı) tablosu ile sunmaktadır (Şekil 7). Bu tablo, modelin sınıflandırma performansını analiz etmek için kullanılan bir grafikdir. Grafikten elde edilen sonuçlar neticesinde modelin, doğru sınıflandırma (Presence-Correct Classified) grubunda yüksek olasılıkla doğru sınıflandırma yaptığı gözlemlenmiştir. Bu değer modelin deniz çayır alanlarını yüksek olasılıkla doğru olarak sınıflandırdığı örnekleri başarılı bir şekilde tanımladığı anlamına gelmektedir. Ancak bazı varlık noktalarının model tarafından yanlış sınıflandırıldığı da gözlemlenmiştir. Bu grafik sonucunda, modelin performansı değerlendirilerek hangi sınıflandırma türlerinin iyileştirilmesi gerektiği ortaya konmuştur.



Şekil 7. Model performansı değerlendirme tablosu

Modelin geçerliliğinin analizin amacıyla eğri altında kalan alan (Area Under the Curve) ve ihmal oranı (Omission Rate) değerleri test edilmiştir. Buna göre model ihmal oranı 0,3265; eğri altında kalan alan oranı ise 0,9072 olarak test edilmiştir. Diğer yandan model doğrulaması amacıyla oluşturulan her bir grubun eğitim ve doğrulama setleri üzerindeki performans değerlendirmeleri dikkate alındığında, gruplara özgü doğruluk oranları %60-80 arasında değişmektedir (Tablo 3).

Tablo 3. Model Çapraz Doğruluk değerlendirilmesinin sonuçları


Grup Kimliği (Group ID)	Eğitim Boyutu (Training Size)	Doğrulama Boyutu (Validation Size)	% Varlık – Doğru Sınıflandırılmış (% Presence – Correctly Classified)	%Arka Plan- Potansiyel Varlık Olarak Sınıflandırıldı (%Background - Classified as Potential Presence)
1	11674	5838	67,98	12,03
2	11675	5837	78,71	20,79
3	11675	5837	62,35	12,41

Yapay zekâ eğitimi sonucunda ihmal oranı (Omission Rate) 0,3265 olarak görülmüştür. Bu oran modelin, bilinen varlık noktalarının %32,65'ini kaçırdığını göstermektedir. Bu oranın düşük olması, modelin varlık noktalarının kaçırma konusunda daha iyi bir performans sergilediğini göstermektedir. Bu değer incelenirken, genellikle başka birimler ile değerlendirilmektedir. Alan Altında Kalan (AUC) değeri modelin performansını değerlendiren bir birimdir. Değer modelin doğruluk oranının ve yanlış pozitif oranını gösterir. 0 ile 1 aralığındadır. 1'e ne kadar yakınsa, model o kadar iyi performans göstermektedir. Modelin AUC değeri 0,9072 olarak gözlemlenmiştir. Bu değerde modelin %90,72 performans ile çalıştığını göstermektedir (Tablo 4).

Tablo 4. Model ihmal oranı ve performans değeri

İhmal Oranı (Omission Rate)	0,3265
AUC	0,9072

Yapılan inceleme, özellikle İskenderun Körfezi, Güney Mısır kıyıları, Ege, Adriyatik, Tunus kıyıları, Sicilya ve Batı Akdeniz’de İspanya’nın doğu kıyıları gibi bölgelerin yüksek olasılık değerlerine sahip olduğunu göstermiştir (Şekil 8). Bu bölgelerdeki yüksek olasılık değerleri çeşitli faktörlerin etkileşimi sonucu ortaya çıkmaktadır. Özellikle büyük akarsu deltalarında, sıcak su akıntılarının etkili olduğu ya da özel konumu nedeniyle denizel biyoçeşitliliğin yüksek olduğu alanlarda, deniz çayırları için uygun yaşam koşullarının oluşma olasılığının arttığı görülmektedir. Çalışmanın bulguları, habitatların dağılımını belirleme ve koruma çabalarını yönlendirme potansiyeline sahiptir. Modelin performansının yüksek olması, bu coğrafi yapay zekâ tekniklerinin, deniz çayırları gibi hassas ekosistemlerin izlenmesi ve korunmasında etkili bir araç olabileceğini göstermektedir.



Şekil 8. Presence-only Prediction (MaxEnt) analizi kullanılarak elde edilen sonuç haritası

Elde edilen sonuç haritası, deniz çayırları habitatlarının olasılık dağılımlarını yüzdelik dilimlerle göstermektedir. %75 ile %100 tahmin değerleri arasında kalan bölgeler hesaplandığında 58.294 km² olarak gözlemlenmiştir. Akdeniz Havzası'nın genel alanı yaklaşık olarak 2.500.000 km²'dir. Hesaplanan alan ise toplam alanın %2,33'ü olarak gözlemlenmiştir. %50 ile %75 tahmin değerleri arasında kalan alanlar 110.262 km²'dir. Bu toplam alanın %4,41'ine denk gelmektedir. %25 ile %50 tahmin değerleri arasında kalan kısım 239.890 km²'dir. Bu toplam alanın %9,59'una denk gelmektedir. %0 ile %25'lik tahmin aralığında kalan değerler ise toplam alanın %82,91'lik kısmını kapsamaktadır, 2.072.982 km² olarak hesaplanmıştır. Elde edilen veriler, mevcut deniz çayır alanları ile karşılaştırılarak yeni ne kadarlık alan tahmin edildiği değerlendirilmiştir. Akdeniz’de güncel olarak 11.559 km² deniz çayır alanı mevcuttur. %75 ile %100'lük tahmin aralığı sonucunda 46.735 km² yeni deniz çayır alanı olabileceği öngörülmüştür.

Harita üzerinde mevcut deniz çayır alanlarının az olduğu fakat tahmin değerlerinin yüksek olduğu bölgeler incelendiğinde, Tunus ve Sicilya Adası arasında kalan Sicilya Boğazı, mevcut deniz çayırı alanların az olduğu fakat analiz sonucunda potansiyel olarak deniz çayırı alanlarının var olabileceği tahmin edilen alandır. Tahmin olasılıklarının yüksek olduğu alanlardan biri de Adriyatik Denizidir. Mevcut deniz çayır alanlarının az rastlandığı bu bölgede, analiz sonuçlarında yüksek değerde tahmin içeren bölgelerdendir. Tahmin bölgelerinin yüksek olduğu bir başka bölge ise Türkiye kıyılarıdır. Ege Denizi’nde bulunan adalar çevresinde küçük alanlarda tespit edilen deniz çayır alanları, bulundukları bölgelerin çevresinde de yüksek olasılıkla gözlemlenebileceği analiz sonucunda tahmin edilmiştir.

Analiz, mevcut alanların değerleri incelenerek yapılmış olup veriler mevcut alanlara göre hazırlanmıştır. Fakat analizin mevcut deniz çayır alanlarını %100 ile tahmin etmediği bölgeler de vardır. Bu bölgeler Sardigna ve Corse adaları kıyılarıdır. Veri setlerinde, ada kıyılarında geniş alanlar kaplayan deniz çayırları, Presence-only Prediction (MaxEnt) aracına göre yanlış sınıflandırılmış ve potansiyel olarak ifade edilmemiştir. Sadece Sardigna Adası güney kıyılarında analiz doğru değerler verdiği gözlemlenmiştir.

Kullanılan veri setinde mevcut deniz çayır alanı olarak belirlenmemiş fakat analiz sonucunda gözlemlenebileceği tahmin edilmiş alanlar vardır. İskenderun Körfezi çevresi ve Akdeniz kıyıları bu alanlardandır. Kıbrıs Adası ile Türkiye arasında kalan Doğu Akdeniz’de deniz çayır alanlarının yüksek değerde gözlemlenebileceği öngörülmüştür.

SONUÇ VE ÖNERİLER

Bu çalışma, Akdeniz’deki deniz çayırı habitatlarının mekânsal dağılımını GeoAI tabanlı Presence-Only Prediciton (MaxEnt) modeli ile tahmin etmeyi amaçlamıştır. Modelleme sonuçlarına göre, %75-%100 aralığında var olduğu tahmin edilen yeni habitat alanı 58.294 km² olarak hesaplanmıştır. Bu değer, Akdeniz havzasının yaklaşık %2,33’üne karşılık gelmektedir. Oran mevcut deniz çayır alanı olan 11.559 km² ile karşılaştırıldığında potansiyel olarak 46.735 km² yeni deniz çayır habitatı olabileceğini göstermektedir.

Literatürde yapılan çalışmalarda (Uzun vd., 2020; Çoban vd., 2020) MaxEnt modelinin %60–%70 doğruluk aralığında sonuçlar ürettiği rapor edilmiştir. Modelin bu doğruluk düzeyi literatür ile paralellik gösterse de veri kalitesi, mekânsal çözünürlük ve çevresel değişkenlerin seçimi analizin doğruluk oranını doğrudan etkilemektedir (Jones & Brown, 2018). Kullanılan veriler iyileştikçe yapılan analizin tutarlılığı doğru oranda artacaktır.

Çalışmanın bulguları, MaxEnt gibi GeoAI modellerinin denizel ekosistemlerin mekânsal planlamasında etkin bir araç olabileceğini göstermektedir. Ayrıca, model sonuçlarının sahaya yönelik gözlemlerle desteklenmesi hem zaman hem de maliyet açısından avantaj sağlayabilir. Özellikle balıkçılık faaliyetlerinin yoğun olduğu Ege kıyıları, İskenderun Körfezi ve Antalya kıyılarında belirlenen yüksek olasılıklı alanlar, sürdürülebilir deniz kaynakları yönetimi açısından stratejik öneme sahiptir.

Sonuç olarak, bu çalışma deniz çayırlarının korunması, yeni habitatların belirlenmesi ve mekânsal planlamanın yönlendirilmesi açısından önemli bir katkı sağlamaktadır. Gelecek çalışmalarda modelleme sürecine daha yoğun saha verisi entegrasyonu ve çok-zamanlı uydu görüntülerinin dahil edilmesi, doğruluk oranını ve model güvenilirliğini daha da artıracaktır.

KAYNAKÇA

- Akçalı, B., Karayalı, S., & diğerleri. (2021). Akdeniz deniz çayırları ve ekosistemi. Akdeniz Üniversitesi Deniz Bilimleri ve Teknolojisi Enstitüsü.
- Boudouresque, C. F., Meinesz, A., & diğerleri. (1982). Posidonia oceanica meadows. Oceanography and Marine Biology: An Annual Review, 20, 153-198.
- Çoban, H. O., Örcü, Ö. K., Arslan, E. S., & diğerleri. (2020). MaxEnt modeling for predicting the current and future potential geographical distribution of Quercus libani. Sustainability, 12, 2671.
- Costanza, R., d'Arge, R., de Groot, R., Farber, S., Grasso, M., Hannon, B., ... van den Belt, M. (1997). The value of the world's ecosystem services and natural capital. Nature, 387(6630), 253-260.
- De Martino, A., & De Martino, D. (2018). An introduction to the maximum entropy approach and its application to inference problems in biology. Heliyon, 4(4), e00596. <https://doi.org/10.1016/j.heliyon.2018.e00596>
- Du, Z., & diğerleri. (2014). MaxEnt applications in health prediction modeling. Journal of Health Informatics, 22(3), 189-204.
- Duarte, C. M., Chiscano, C. L., & diğerleri. (1999). Seagrass biomass and production: A reassessment. Aquatic Botany, 65(1-4), 159-174.
- Dural, B., Ertan, K. T., Çetin, H., & Yüce, H. (2013). Denizel çayırların biyolojik önemi ve türlerine genel bir bakış. Karadeniz Fen Bilimleri Dergisi, 3(1), 44-51.

- Elith, J., & diğerleri. (2011). A statistical explanation of MaxEnt for ecologists. *Diversity and Distributions*, 17(1), 43-57.
- Fithian, W., & diğerleri. (2013). Statistical analysis using MaxEnt: An overview. *Journal of Statistical Applications*, 45(2), 89-105.
- Jones, B., Brown, C., & diğerleri. (2018). Factors influencing the performance of GeoAI models: A comprehensive review. *International Journal of Geographic Information Science*, 25(4), 567-589.
- Lahoz-Monfort, J. J., Magrath, M. J. L., & diğerleri. (2021). A comprehensive overview of technologies for species and habitat monitoring and conservation. *BioScience*, 71(10), 1038–1062.
- Mainwaring, A., Culler, D., Polastre, J., Szewczyk, R., & Anderson, J. (2002). Wireless sensor networks for habitat monitoring. In *WSNA '02: Proceedings of the 1st ACM International Workshop on Wireless Sensor Networks and Applications* (pp. 88–97). <https://doi.org/10.1145/570738.570751>
- Mobley, S., & diğerleri. (2019). MaxEnt in disaster management: A case study of flood prediction. *International Journal of Disaster Risk Reduction*, 33, 120-135.
- Nellemann, C. (Ed.). (2009). *Blue carbon: The role of healthy oceans in binding carbon*. UNEP/GRID-Arendal.
- Pasqualini, V., & diğerleri. (1997). Utilisation de la télédétection pour l'inventaire et la cartographie des herbiers marins. *MIO-ECSDE*.
- Short, F. T., Wyllie-Echeverria, S., & diğerleri. (1996). Natural and human-induced disturbance of seagrasses. *Environmental Conservation*, 23(1), 17-27.
- Smith, A., & diğerleri. (2020). The use of GeoAI models in determining live habitats. *Journal of GeoAI*, 5(2), 87-105.
- Uzun, A., Aksu, B., Uzun, T., & diğerleri. (2020). MaxEnt modeli kullanılarak *Acer campestre* L. subsp. *campestre* (Ova Akçaağacı)'nin tahmini olarak günümüz ve gelecekteki yayılış alanlarının belirlenmesi. *Türkiye Peyzaj Araştırmaları Dergisi*, 3(2), 108-119.
- Vaachi, A., & diğerleri. (2014). Deniz çayırları üzerine yapılan çalışmalarda belirsizlikler. *Deniz Araştırmaları Dergisi*, 21(3).



© Author(s) 2025. This work is distributed under
<https://creativecommons.org/licenses/by-nc/4.0/>