

# Evrişimsel Sinir Ağlarıyla Marmara Denizi'ndeki Müsilaj Oluşumlarının Tespitinde Eğitim Veri Seti Boyutunun Etkisinin İncelenmesi

## Examining the Effect of Training Data Set Size on the Detection of Mucilage Formations in the Sea of Marmara with Convolutional Neural Networks

**Dr. Öğr. Üyesi Meltem ÇELEN**

Gebze Teknik Üniversitesi, Yer ve Deniz Bilimleri Enstitüsü, Kocaeli, Türkiye  
mkocal@gtu.edu.tr  
ORCID: 0000-0001-9487-497X

**Prof. Dr. Mehmet Salim ÖNCEL**

Gebze Teknik Üniversitesi, Yer ve Deniz Bilimleri Enstitüsü, Kocaeli, Türkiye  
soncel@gtu.edu.tr  
ORCID: 0000-0002-1945-2336

**Arş. Gör. Mustafacan SAYGI**

Gebze Teknik Üniversitesi, Yer ve Deniz Bilimleri Enstitüsü, Kocaeli, Türkiye  
msaygi@gtu.edu.tr  
ORCID: 0009-0003-6015-1273

**Doç. Dr. İsmail ÇÖLKESEN**

Gebze Teknik Üniversitesi, Yer ve Deniz Bilimleri Enstitüsü, Kocaeli, Türkiye  
mkocal@gtu.edu.tr  
ORCID: 0000-0001-9670-3023

### Öz

Ekosistem için büyük önem arz eden denizel ortamlarda meydana gelen olumsuz değişimlerin önüne geçilebilmesi için alınacak önlemlerin belirlenmesinde takip ve izleme sistemlerinin geliştirilmesi kritik bir rol oynamaktadır. Bu noktada her geçen gün ilerleyen sensör teknolojisinin ürünü olan uzaktan algılanmış görüntülerin kullanılması çevresel değişim analizlerde önemli avantajlar sunmaktadır. Bunun yanı sıra, derin öğrenme tekniklerinin kullanılması da bu karmaşık ve büyük hacimli uzaktan algılanmış veri setlerinden daha yüksek performans alınmasını sağlamaktadır. Bu çalışmada, 2021 yılında Marmara Denizi'nin doğusunda yer alan Kocaeli Körfezi'nde gözlemlenen müsilaj oluşumlarının uydu görüntüleri ve derin öğrenme modelleri ile tespiti ve haritalandırılması hedeflenmiştir. Çalışmada atmosferik olarak düzeltilmiş Sentinel-2 (Seviye-2) görüntüleri temel veri kaynağı olarak kullanılmış ve piksel tabanlı Evrişimsel Sinir Ağları (ESA) mimarisine dayalı derin öğrenme modelleriyle sınıflandırma yapılmıştır. Bu kapsamda, ESA modellerinin sınıflandırma performansı, model oluşumunda kullanılan eğitim veri setinin boyutuyla ilişkili olarak detaylı bir şekilde ele alınmıştır. Sentinel-2 uydu görüntülerinin yeniden örneklenmesi ve kara piksellerinin maskelenmesinin ardından çalışma alanında yer alan temiz su yüzeyi ve müsilaj oluşumlarına yönelik örnek pikseller toplanmıştır. Derin öğrenme modellerinin eğitim ve test aşamasında kullanılmak üzere elde edilen örnek piksellerden oluşan veri seti boyutunun müsilaj oluşumlarının tespitine etkisinin incelenmesi amacı ile yer doğrulama veri seti örnekleme oranları dikkate alınarak belirlenmiştir. Çalışma sonuçları, model oluşumunda kullanılan örnek sayısının artması ile birlikte tahmin modelinin performansında %7 seviyelerinde artış olduğunu göstermektedir. Bununla birlikte 19 Mayıs 2021 tarihinde çalışma alanında 4km<sup>2</sup>'lik bir alana yayılan yoğun müsilaj oluşumları tespit edilmiştir. Elde edilen nicel değerlendirmeler sonucunda daha geniş veri setlerinin derin öğrenme modellerinin sınıflandırma doğruluğuna katkı sağladığı görülmüştür.

**Anahtar Kelimeler:** Derin Öğrenme, Evrişimsel Sinir Ağları, Müsilaj, Sentinel-2, Uzaktan Algılama.

## Abstract

The development of tracking and monitoring systems plays a critical role in determining the measures to be taken to prevent negative changes in marine environments, which are of great importance for the ecosystem. At this point, the use of remotely sensed images, which are the product of sensor technology that advances day by day, offers significant advantages in environmental change analyses. In addition, the use of deep learning techniques provides higher performance from these complex and large volume remotely sensed data sets. In this study, it was aimed to detect and map the mucilage formations observed in Kocaeli Bay, located in the east of the Marmara Sea in 2021, with satellite images and deep learning models. In this study, atmospherically corrected Sentinel-2 (Level-2) images were used as the main data source and classification was made with deep learning models based on pixel-based Convolutional Neural Networks (ESA) architecture. In this context, the classification performance of ESA models is discussed in detail in relation to the size of the training data set used in model formation. After resampling the Sentinel-2 satellite images and masking the land pixels, sample pixels for the clean water surface and mucilage formations in the study area were collected. In order to examine the effect of the size of the data set, which consists of sample pixels obtained for use in the training and testing stages of deep learning models, on the detection of mucilage formations, the ground validation data set was determined by taking into account the sampling rates. The study results show that as the number of samples used in model formation increases, there is a 7% increase in the performance of the prediction model. However, on May 19, 2021, dense mucilage formations spread over an area of 4 km<sup>2</sup> were detected in the study area. As a result of the quantitative evaluations obtained, it was seen that larger data sets contributed to the classification accuracy of deep learning models.

**Keywords:** Deep Learning, Convolutional Neural Networks, Mucilage, Sentinel-2, Remote Sensing.

## Giriş

Gün geçtikçe artan nüfus yoğunluğunun ihtiyaçlarının giderilmesi amacıyla hızla artan sanayileşme, gerekli ham maddenin temini için artan tarımsal faaliyetler, nüfusa bağlı artan antropojenik etkiler ve en önemlisi küresel ısınmayla birlikte iklim değişikliğinin etkileri her geçen gün ekosistemde büyük değişiklikler meydana getirmektedir. Hem denizlerde hem de karasal ekosistemde meydana gelen değişikliklere bu ortamlarda yaşayan canlılar farklı tepkiler verebilmektedir. Denizel ortamlardaki canlıların en çarpıcı tepkilerinden biri de müsilaj oluşumdur. Müsilaj, genel olarak deniz karı, kümelenmiş kütle, köpük birikimi, flokülasyon ve mukus aglomerasyonu gibi terimlerle de tanımlanmaktadır (Özalp, 2021). Deniz salyası olarak da adlandırılan bu oluşumların temel nedeni ise planktonik organizmalar ve filamentli alglere dayanmaktadır (Schiaparelli vd., 2007). Genellikle ani değişimler sonucu meydana gelen müsilaj oluşumlarında karasal girdilerin etkili olduğu bilinmekle beraber büyük oranda belirsizlik de bulunmaktadır (Cozzi vd., 2004). Müsilaj oluşumlarındaki artışın, alt tabakadaki çözünmüş oksijen seviyelerinin

tükenmesine neden olarak, ekosistemde bir çöküşe yol açabileceği ifade edilmektedir (Taş vd., 2020). Dolayısıyla hem deniz ekosistemini hem de dolaylı olarak karasal ekosistemin çevresel olarak korunması amacıyla gerekli önlemlerin alınmasına ihtiyaç duyulmaktadır. Bu doğrultuda, gerekli önemlerin alınabilmesi ve karar vericilere gerekli bilgilerin sağlanabilmesi amacıyla bu oluşumlara neden olan faktörlerin ortaya çıkarılması, meydana geldiği süreçlerde takip ve tespit edilmesi büyük önem arz etmektedir.

Nitekim, özellikle geniş kapsama alanlarına sahip veri teminine olanak sağlayan uzaktan algılama teknolojilerinin kullanımı bu konudaki araştırmalara büyük katkı sağlamaktadır. Her geçen gün gelişen sensör teknolojisi sayesinde yer gözlemine dayalı uygulamalarda daha yüksek seviyede özelliklerin elde edilmesini sağlayan uzaktan algılanmış görüntülerden oluşan veri setleri; su kalitesinin değerlendirilmesi, alg patlaması oluşumlarının tespiti, su alanlarının çıkarımı gibi çeşitli çalışma alanlarında sıklıkla kullanılmaktadır (Colkesen vd., 2024; Mishra ve Mishra, 2024; Wasehun vd., 2024; Sun vd., 2024). Bunun yanı sıra, son dönemin popüler teknolojisi olan yapay zekaya dayalı derin öğrenme teknikleri de düşük seviyeli ham verilerden elde edilen özelliklerden daha yüksek seviyede bilgi çıkarımına olanak tanınması nedeniyle kompleks veri seti olarak nitelendirilebilen uzaktan algılanmış veri setlerinde sıklıkla tercih edilmektedir (Kattenborn vd., 2021; Hou vd., 2021; Hu vd., 2021; Kaushal vd., 2024; Xue vd., 2024).

Hali hazırda mevcut literatür göz önünde bulundurulduğunda, müsilaaj formasyonlarının tespitinde birçok farklı teknik ve veri seti kullanılarak çalışmalar gerçekleştirilmiştir (Kavzoglu vd., 2021; Acar vd., 2021; Kavzoglu ve Goral, 2022; Yagci vd., 2022; Colkesen vd., 2023; Sefercik vd., 2024; Yılmaz vd., 2024; Esi vd., 2024). Örneğin Acar vd. (2021) tarafından gerçekleştirilen çalışmada bulut tabanlı Google Earth Engine platformunda Sentinel-2 uydu görüntülerinin temel veri seti olarak kullanılmış olup makine öğrenmesi algoritmalarından Rastgele Orman algoritması sınıflandırma aşaması için tercih edilmiştir. Müsilaaj oluşumlarının tespitine yönelik gerçekleştirilen başka bir çalışmada Yagci vd. (2022) günlük veri almına olanak sağlayan ancak düşük mekânsal çözünürlüğe sahip Moderate Resolution Imaging Spectroradiometer (MODIS) uydu görüntülerinin müsilaaj oluşumlarının günlük olarak izlenmesi ve tespitini incelemiştir. MODIS uydu görüntüleri ile elde edilen sonuçlar hem Sentinel-2 uydu görüntüleriyle hem de yersel ölçümlere dayalı spektrometre ölçümleriyle doğrulanmıştır. Diğer taraftan nitel ve nicel sonuçlar, üretilen haritalarda kara-su geçiş bölgelerinde sınırlı güvenilirlik olsa da müsilaaj oluşumlarını doğru bir şekilde tespit edebilmektedir. Colkesen vd. (2023) tarafından gerçekleştirilen çalışmada, müsilaaj oluşumlarının tespitine yönelik Sentinel-2 uydu görüntüleri kullanılarak Otomatik Müsilaaj Çıkarım İndeksi (AMEI) önerilmiştir. Üç farklı tarihte Marmara Denizi'nde meydana gelen müsilaaj oluşumlarına dayalı olarak geliştirilen AMEI, Jenks Natural Breaks (JNB) eşik değer algoritmasına dayalı olarak otomatik eşik değer tayini uyarınca geliştirilmiştir. Diğer taraftan önerilen yöntem, 21 farklı spektral indeksle karşılaştırılmış olup elde edilen yöntemin etkinliği vurgulanmıştır. Sefercik vd. (2024) tarafından gerçekleştirilen çalışmada ise müsilaajın deniz suyu kalitesi, deniz yüzeyi sıcaklığı ve radar sinyali yansıma gücü üzerindeki etkileri, müsilaajla kaplı iki farklı bölgede yapılan detaylı bir araştırma ile değerlendirilmiştir. Yersel ölçümlere dayalı su yüzeyi sıcaklığı, elektriksel iletkenlik, pH, askıda katı maddeler, çözünmüş oksijen ve klorofil-a gibi su kalitesi parametreleri de çalışma kapsamında elde edilmiştir. Ayrıca, yine yersel ölçümlere dayalı olarak farklı müsilaaj formasyonları ve temiz su yüzeyine ait spektral yansıma değerleri elde edilmiştir. Bunun yanı sıra uzay tabanlı Sentinel-1, Sentinel-2 ve Sentinel-3 radar ve optik görüntüleri kullanılarak, müsilaajın deniz yüzeyi sıcaklığı, spektral yansıma ve radar sinyali geri saçılma üzerindeki etkileri incelenmiştir. Sonuçlar, müsilaajın su kalitesi üzerinde belirgin etkiler yarattığını ve orta ile yoğun müsilaajın radar sinyali gücünde sırasıyla yaklaşık 0,5 ve 1 desibel azalmaya neden olduğunu göstermiştir. Ayrıca, deniz yüzeyi sıcaklığı açısından, temiz su ile orta yoğunluklu ve yoğun müsilaaj alanları arasındaki farkın 1,05-2,25°C arasında olduğu ortaya konmuştur.

Çalışma kapsamında, Marmara Denizi'nin doğusunda yer alan Kocaeli Körfezi'nde meydana gelen müsilaaj oluşumlarının Evrişimsel Sinir Ağları (ESA) tabanlı derin öğrenme teknikleri ve Sentinel-2 uydu görüntüleri ile tespit edilmesinde eğitim veri seti boyutunun, sınıflandırma performansına etkisi incelenmiştir.

## Yöntem

Gerçekleştirilen çalışma kapsamında uygulanan yöntem adımları üç temel başlık altında toplanmıştır. İlk olarak temel veri seti olarak kullanılacak Sentinel-2 uydu görüntüleri, çalışma alanında müsilaj oluşumlarının gözlemlendiği tarihte temin edilmiştir. Ardından temin edilen uydu görüntülerinin yeniden örneklenmesi ve kara alanlarının maskelenmesi gibi ön işlemleri gerçekleştirilmiş ve derin öğrenme modellerinin eğitim aşamasında kullanılmak üzere eğitim ve test veri setleri oluşturulmuş ve çalışmanın amacına yönelik olarak rastgele bölünmüştür. Son olarak sınıflandırma işlemlerinin gerçekleştirilmesi için kullanılacak ESA tabanlı derin öğrenme modelleri oluşturulmuş ve sınıflandırma işlemleri gerçekleştirilmiştir.

## Çalışma Alanı ve Veri Seti

Çalışma kapsamında uygulama alanı olarak, 2021 yılında yoğun müsilaj oluşumlarının gözlemlendiği Marmara Denizi'nin doğusunda yer alan İzmit Körfezi seçilmiştir (Şekil 1). Marmara Bölgesi'nin doğusunda yer alan ve yoğun sanayi faaliyetlerinin merkezi konumunda bulunan Kocaeli ilinin kıyı şeridi içerisinde kalan çalışma alanı yaklaşık 210 km<sup>2</sup>'lik bir alanı kapsamaktadır. Bölgenin Türkiye'nin en önemli sanayi merkezlerinden biri konumunda olması, nüfusun hızla artmasına neden olmuştur. Son beş yıllık nüfus ölçümlerine göre, Kocaeli'nin nüfusunun %20 oranında bir artış göstererek 2.102.907 kişiye ulaştığı tespit edilmiştir (TUIK, 2023).



Şekil 1. Çalışma Alanı.

Çalışma kapsamında, temel veri seti olarak Avrupa Uzay Ajansı tarafından Copernicus programının Sentinel-2 uydu misyonu tarafından servis edilen uydu görüntüleri kullanılmıştır. Yer gözlemine dayalı uygulamalar için geliştirilen Sentinel-2 uydu misyonu Sentinel-2A ve Sentinel-2B güneşe eş yörüngede bulunan ikiz uydulardan oluşmaktadır. Üç farklı mekânsal çözünürlük tipi sunan Sentinel-2 uydu görüntüleri, 10 m mekânsal çözünürlüğe sahip 4 spektral banda, 20 m mekânsal çözünürlüğe sahip 6 spektral banda ve 60 m mekânsal çözünürlüğe sahip 3 spektral banda sahiptir. Beş günlük zamansal çözünürlüğe sahip Sentinel-2 uydu görüntüleri, kızılötesi ve kırmızı kenar dalga boyu aralığında 5 farklı spektral banda ve açık erişime sahip olması nedeniyle birçok araştırmada kullanılmaktadır. Sentinel-2 uydu görüntülerine ait teknik özellikler Tablo 1'de verilmiştir.

**Tablo 1: Sentinel-2 Uydu Görüntülerinin Teknik Özellikleri.**

Bant Numarası	Spektral Bölge	Merkez Dalgaboyu (nm)	Mekansal Çözünürlük (m)
B01	Kıyı Aerosol	443	60
B02	Mavi	490	10
B03	Yeşil	560	10
B04	Kırmızı	665	10
B05	Kırmızı kenar	705	20
B06	Kırmızı kenar	740	20
B07	Kırmızı kenar	783	20
B08	Yakın Kızılötesi	842	10
B8A	Kırmızı Kenar	865	20
B09	Su Buharı	945	60
B10	Kısa Dalga Kızılötesi	1380	60
B11	Kısa Dalga Kızılötesi	1610	20
B12	Kısa Dalga Kızılötesi	2190	20

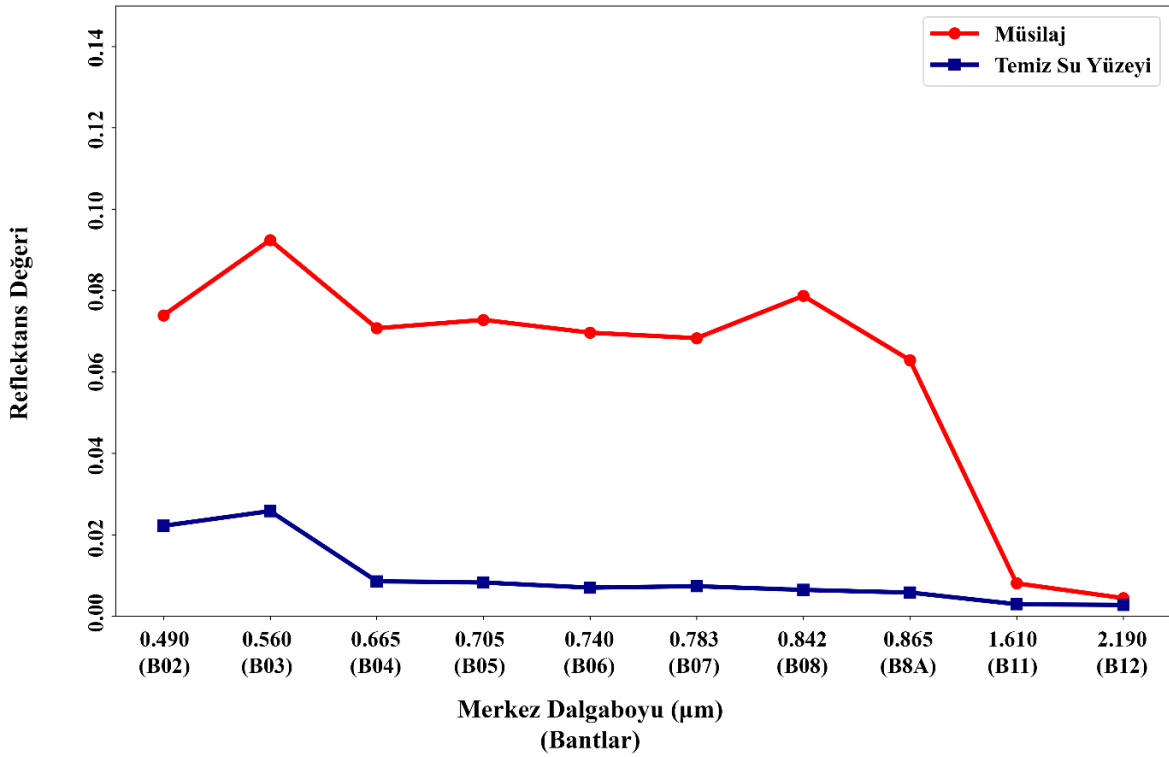
## Veri Temini ve Ön İşlemler

Temel veri olarak kullanılan, çalışma alanında müsilaaj formasyonlarının gözlemlendiği 19 Mayıs 2021 tarihli Sentinel-2 uydu görüntüsü Avrupa Uzay Ajansı Copernicus Açık Erişim Merkezi'nden (<https://dataspace.copernicus.eu/>) temin edilmiştir. Sentinel-2 uydu görüntüsü; atmosferik, radyometrik ve geometrik düzeltmeleri gerçekleştirilmiş Seviye-2 olarak temin edilmiştir. Müsilaaj

oluşumlarının daha hassas ve yüksek doğrulukta tespiti amacıyla çalışma alanında bulut içermeyen görüntüler tercih edilmiştir. Elde edilen görüntünün 60 m mekânsal çözünürlüğe sahip kıyı aerosolleri, atmosferik etkiler ve su buharı gibi çalışmalar için kullanılan Kıyı Aerosol (B01), Su Buharı (B09) ve Kısa Dalga Kızılötesi - Sırrus (B10) bantları veri setinden çıkarılmış olup geriye kalan 10 spektral bant çalışmada kullanılmıştır. Veri setinden yer alan 20 m mekânsal çözünürlükteki spektral bantlar, 10 m mekânsal çözünürlükteki diğer spektral bantların çözünürlüğüne eşitlenebilmesi adına literatürde sıklıkla kullanılan en yakın komşuluk enterpolasyon tekniği yardımıyla 10 m mekânsal çözünürlüğe yeniden örneklenmiştir (Wang vd., 2016). Veri setinin çözünürlüğünün iyileştirilmesi amacıyla gerçekleştirilen işlemler ENVI 5.3 yazılımı kullanılarak gerçekleştirilmiştir.

Yeniden örneklenen veri seti üzerinde kara alanlarının maskelenmesi literatürde birçok çalışmada su alanlarının çıkarımında yaygın olarak kullanılan Modifiye Normalize Edilmiş Fark Su İndeksi'nden (MNDWI) yararlanılmıştır (Xu, 2006). Veri setinin Yeşil (B03) ve Kısa Dalga Kızılötesi-1 (B11) spektral bantlarını esas alınarak hesaplanan bu spektral indeks, -1 ile +1 değer aralığına sahip olmakla beraber negatif değerler kara piksellerine karşılık gelirken pozitif değerler su piksellerini temsil etmektedir. Çalışma kapsamında, belirtilen veri seti kullanılarak oluşturulan gri-düzyen indeks haritası üzerinden, görsel yorumlamaya dayalı eşik tayini kullanılarak kara alanları maskelenmiştir. Bununla birlikte, çalışmada daha hassas bir sonuç elde edilebilmesi için görüntüde yer alan gemilere ait pikseller de maskelenmiş olup yalnızca müsilaaj ve su piksellerinden oluşan görüntü elde edilmiştir.

Gerçekleştirilecek sınıflandırma işleminde kullanılacak eğitim ve test veri setinin oluşturulması amacıyla çalışma alanında yer alan temiz su yüzeyi ve müsilaaj oluşumlarına ait örnek pikseller toplanmıştır. Müsilaaj oluşumlarına yönelik toplanan örnek pikseller Colkesen vd. (2022) tarafından gerçekleştirilen çalışmada belirtilen orta ve düşük yoğunluktaki müsilaaj oluşumları da göz önünde bulundurularak toplanmıştır. Görsel yorumlamaya dayalı gerçekleştirilen bu işlemlerin daha hassas bir şekilde gerçekleştirilebilmesi amacıyla yalancı renk kombinasyonlarından yararlanılmıştır. Toplanan örnek piksellerin spektral yapısı analiz edilmiş olup ortalama ve standart sapma değerlerine bağlı olarak aykırı değerler elimine edilmiştir. Son durumda sınıflandırma işleminde kullanılmak üzere her iki sınıfa ait 1500'er örnek piksel kullanılarak veri seti oluşturulmuştur. Şekil 2'de su ve müsilaaj örnek piksellerine ilişkin ortalama spektral imzaları verilmiştir. Spektral imzalar incelendiğinde müsilaaj oluşumlarının hem spektrumun hem görünür bölgesinde hem de kızıl ötesi bölgesinde su piksellerinden oldukça farklı spektral karakteristiği olduğu görülmektedir. Bununla birlikte, su ve müsilaaj oluşumlarının Sentinel-2 görüntüsünün orta kızılötesi bantlarında (B11 ve B12) spektral olarak benzer değerler aldığı görülmektedir.



Şekil II. Müsilaj ve Su Piksellerinin Spektral İmzaları.

## Evrişimsel Sinir Ağları (ESA)

Çalışma kapsamında, gerçekleştirilen sınıflandırma işlemleri için Evrişimsel Sinir Ağları mimarisinin temel alındığı piksel-tabanlı derin öğrenme tekniği kullanılmıştır. Özellikle ESA mimarisine dayalı derin öğrenme tekniklerinin, büyük veri boyutuna ve kompleks yapıya sahip uzaktan algılanmış görüntülerde özellik öğrenme özelliği sayesinde sınıflandırma performansına katkı sağlamaktadır (Zhang vd., 2019). Bunun yanı sıra geleneksel tabanlı yöntemlere kıyasla düşük seviyeli özellikler olarak nitelendirilebilen ham verilerden yüksek seviyede ve derin özelliklerin çıkarılmasını sağlaması farklı durumlara kolay adapte olabilmesini ve dolayısıyla transfer edilebilir bir model geliştirilmesine katkı sunmaktadır (Hinton and Salakhutdinov, 2006; Wang vd., 2018). Çalışma kapsamında tasarlanan ESA tabanlı derin öğrenme modellerinde 2 ardışık konvolüsyon katmanları ve ardından her biri 1 x 1

çekirdek (Kernel) boyutuna sahip ReLU aktivasyon fonksiyonu ile etkinleştirilmiştir. Evrişim katmanlarının ardından elde edilen özellikler düzleştirme (Flatten) katmanı ile vektörel formata dönüştürülmüştür. Bu işlemi takiben iki tam bağlı (Dense) katman kullanılmış olup ReLU aktivasyon fonksiyonu kullanılarak doğrusal olmayan ilişkilerin modellenmesi amaçlanmıştır. Modelin aşırı öğrenme durumunu ortadan kaldırmak ve genelleme kapasitesini artırmak amacıyla %20'lik seyreltme (Dropout) kullanılmış ve bazı nöronlar rastgele olacak şekilde devre dışı bırakılmıştır. Son aşamada ise modelin son katmanında, iki sınıflı bir sınıflandırma problemi için softmax aktivasyon fonksiyonu ile çalışan bir çıktı katmanı yer almaktadır. Çalışmanın amacına yönelik olarak farklı eğitim veri setlerinin performanslarının daha objektif bir şekilde değerlendirilebilmesi için tüm model eğitimlerinde ESA tabanlı model mimarisi aynı şekilde kullanılmıştır.

## Sonuçlar ve Tartışma

Çalışmanın temel amacı, mülaj oluşumlarının tespiti-ne yönelik farklı eğitim veri seti boyutları dikkate alınarak oluşturulan ESA modellerinin performanslarının analiz edilmesidir. Bu doğrultuda, görüntü üzerinde su ve mülaj oluşumlarını temsil eden toplam 3.000 pikselden oluşan yer doğrulama verisi, rastgele örnekleme prensibine dayalı olarak Tablo II’de verilen farklı örnekleme oranları dikkate alınarak eğitim ve test veri seti olarak ayrılmıştır. Elde edilen veri setinin eğitim ve test sayısına yönelik bilgilere Tablo II’de yer verilmiştir.

**Tablo II: Derin Öğrenme Modelinin Eğitim ve Test Aşamalarında Kullanılan Pikselle Sayıları.**

Bant Numarası	Spektral Bölge	Merkez Dalgaboyu (nm)
10:90	300	2700
30:70	900	2100
50:50	1500	1500
70:20	2100	900
90:10	2700	300

Tablo II’de yer alan farklı eğitim boyutlarına sahip veri setleri kullanılarak eğitilen derin öğrenme modellerinin performanslarının objektif bir şekilde karşılaştırılabilmesi amacıyla model hiper-parametreleri tüm modellerde sabit tutulmuştur. Bu kapsamda model hiper-parametreleri deneme yanılma stratejisine bağlı olarak belirlenmiş olup Tablo III’te belirtilmiştir.

**Tablo III: Derin Öğrenme Modellerinin Eğitim Aşamasında Kullanılan Hiper Parametreler.**

Hiperparametre	Değer
Optimizatör	Adam
Öğrenme Oranı	0.001
Kayıp Fonksiyonu	Kategorik Çapraz Entropi
Batch Boyutu	16
Eğitim Tur Sayısı	10

Derin öğrenme modelleri Tablo III’te belirtilen hiper parametreler kullanılarak ayrı ayrı eğitilmiş olup eğitim süreçlerinde herhangi bir şekilde “aşırı öğrenme” ve “yetersiz öğrenme” olmamıştır. Model eğitimlerinde, eğitim tur sayısının 10 olarak belirlenmesinin en temel nedeni derin öğrenme modellerinin yüksek işlem kapasiteli iş istasyonlarına ihtiyaç duymasının yanı sıra sınıflandırma probleminin nispeten ikili sınıflandırma problemi (mülaj ve su) olarak basit bir problem olarak nitelendirilebilir olmasından kaynaklanmaktadır. Modellerin eğitim süreçlerinin

değerlendirilebilmesi için her bir eğitim tur sayısında elde edilen eğitim ve doğrulama kayıp grafikleri oluşturulmuştur. Ayrıca, her bir derin öğrenme modeli için en az eğitim kaybının yaşandığı eğitim tur sayısı model tahmin aşamasında kullanılmak üzere belirlenmiştir.

Derin öğrenme modellerinin eğitim aşamasının ardından modellerin performanslarının değerlendirilmesi amacıyla literatürde derin öğrenme ve uzaktan algılama tabanlı uygulamalarda sıklıkla tercih edilen doğruluk analizi metrikleri kullanılmıştır. Doğruluk analizi metriklerine ilişkin eşitlikler aşağıda verilmiştir.

$$\text{Kesinlik} = \frac{DY}{DP + YP}$$

$$\text{Hassasiyet} = \frac{DP}{DP + YN}$$

$$F - \text{Skor} = \frac{2 \times \text{Kesinlik} \times \text{Hassasiyet}}{\text{Kesinlik} + \text{Hassasiyet}}$$

$$IoU = \frac{DP}{DP + YP + YN}$$

$$\text{Genel Doğruluk} = \frac{DP + DN}{DP + DN + YP + YN}$$

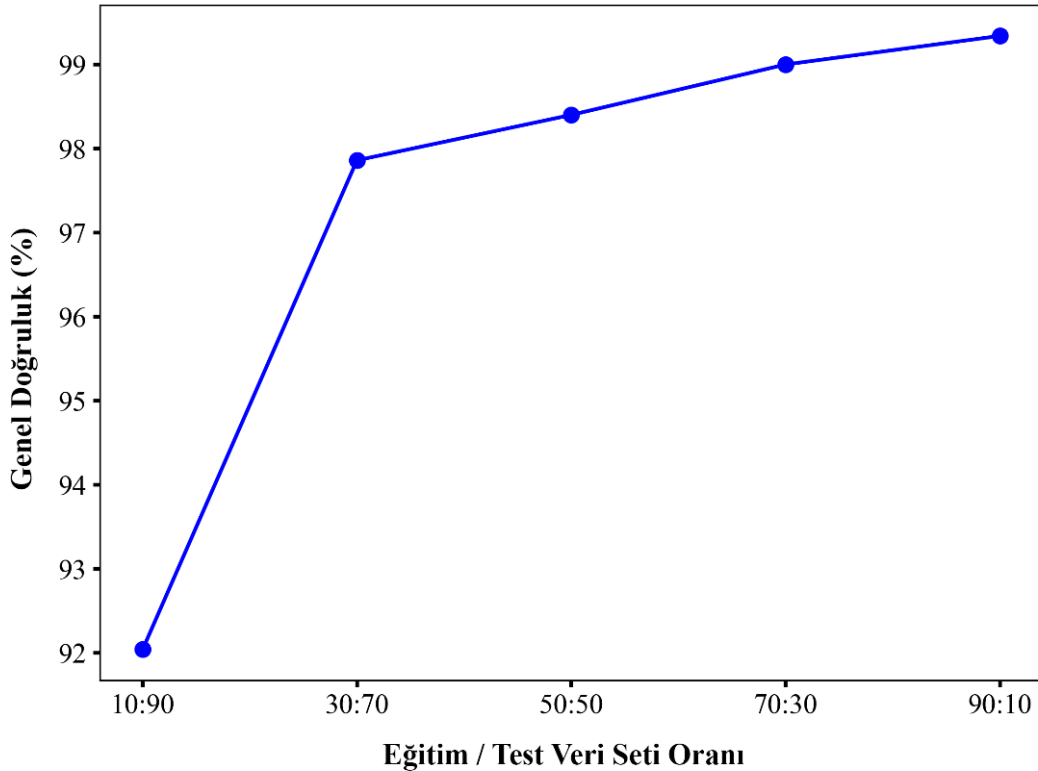
Bu kapsamda, modellerin tahmin sonuçları ve test pikselleri kullanılarak hata matrisi üretilmiştir. Ardından sınıf bazlı doğruluk değerlendirmesi için Doğru Pozitif (DP), Doğru Negatif (DN), Yanlış Pozitif (YP) ve Yanlış Negatif (YN) değerleri hesaplanmış olup bu kapsamda kesinlik, hassasiyet, f-skor, genel doğruluk ve birleşim üzerinde kesişim metrikleri hesaplanmıştır. Doğru pozitiflerin sayısının, doğru pozitifler ve yanlış pozitiflerin toplamına bölünmesiyle elde edilen kesinlik metriği, tahmin edilen piksellerin ne kadarının eksiksiz tahmin edildiğine yönelik bilgi vermesi amacıyla kullanılmıştır. Diğer taraftan hassasiyet ise doğru pozitiflerin sayısının doğru pozitif ve yanlış negatiflerin sayısının toplamına bölünmesiyle elde edilmektedir. Diğer taraftan bireysel kullanımında net bir şekilde sınıflandırma doğruluğunun elde edilmesine katkı sağlamayan kesinlik ve hassasiyet metriklerinin harmonik ortalaması olarak elde edilen f-skor metriği hesaplanmıştır. Bunun yanı sıra kesişim alanlarının birleşim alanlarına oranıyla elde edilen birleşim üzerinde kesişim (IoU) ve hata matrisinde yer alan tüm bileşenlerin formülasyonuna dahil edildiği genel doğruluk (GD) metrikleri hesaplanmıştır. Uygulanan modellerin farklı metrikler için doğruluk analizi sonuçları Tablo IV’te belirtilmiştir.

**Tablo IV: Doğruluk Analizi Sonuçları.**

Metrik	10:90	30:70	50:50	70:30	90:10
<b>Kesinlik (%)</b>	92,97	97,88	98,39	98,99	99,33
<b>Hassasiyet (%)</b>	92,12	97,87	98,43	99,02	99,33
<b>F-Skor (%)</b>	92,01	97,86	98,40	99,00	99,33
<b>IoU (%)</b>	85,20	95,81	96,85	98,02	98,68
<b>GD (%)</b>	92,04	97,86	98,40	99,00	99,34

Elde edilen sonuçlar göz önünde bulundurulduğunda tüm doğruluk analizi metriklerinde en yüksek eğitim veri seti boyutuna sahip veri seti kullanılarak eğitilen derin öğrenme modelinin en yüksek sınıflandırma performansına sahip olduğu görülmüştür. Bunun yanı sıra 10:90 dağılımına sahip veri setinin ardından doğruluk oranında %5'in üzerinde bir artış sağlanmasına karşın 30:70 veri setinin ardından doğruluk oranlarındaki artış boyutu %1'in altına düşmüştür. Özellikle IoU metriği baz alınarak gerçekleştirilen

analizde 10:90 ve 30:70 veri setleri kullanılarak eğitilen derin öğrenme modelinin %10'un üzerinde bir farka sahip olduğu görülmektedir. Genel doğruluk metriğindeki değerlere benzer şekilde 30:70 veri seti dağılımıyla eğitilen derin öğrenme modelinin ardından doğruluk oranlarındaki artış azalma eğilimi göstermiştir. Buna yönelik olarak her bir eğitim veri setinde derin öğrenme modellerinin genel doğruluk oranlarının dağılımı Şekil III'te gösterilmiştir.



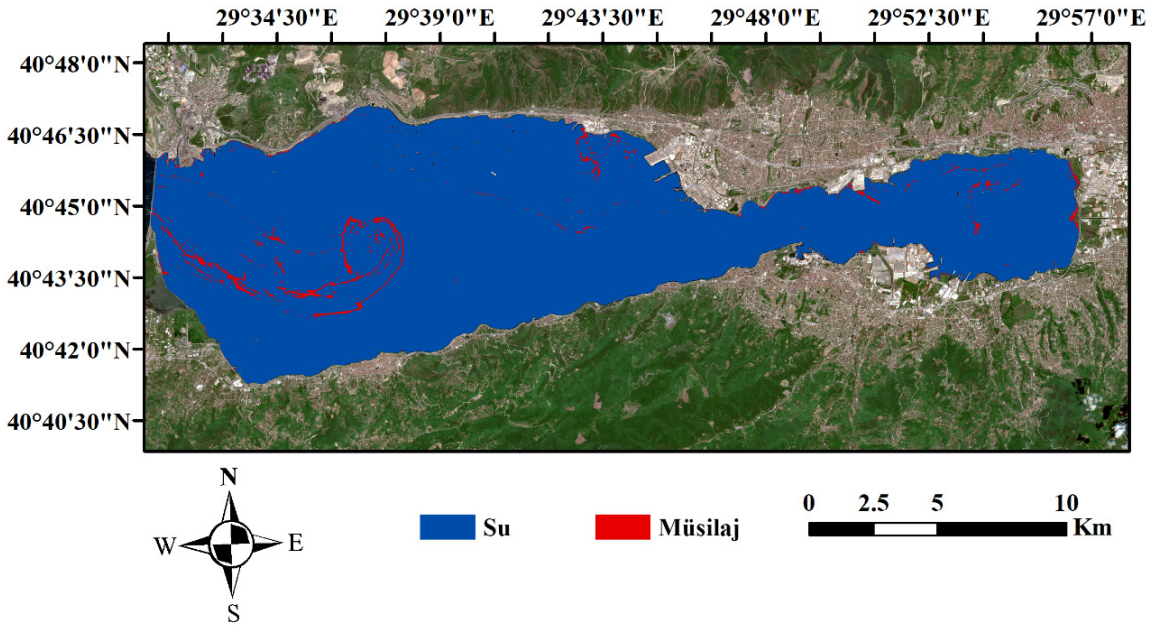
**Şekil III. Derin Öğrenme Modellerinin Eğitim Veri Setine Göre Genel Doğruluk Oranları.**



Geleneksel yöntemlere ve makine öğrenmesi algoritmalarına göre düşük seviyeli özelliklerden yüksek seviyeli özelliklerin çıkarılmasına katkı sağlayan derin öğrenme modelleri, bu yöntemlere kıyasla daha yüksek boyutlara sahip veri setlerine ihtiyaç duymaktadır. Nitekim bu durum göz önünde bulundurulduğunda derin öğrenme modellerinin daha yüksek sınıflandırma performansına sahip olduğu da çalışma kapsamında gerçekleştirilen uygulamada görülmüştür. Farklı veri seti boyutları kullanılarak eğitilen derin öğrenme modellerinin doğruluk analizi sonucu elde edilen genel doğruluk oranları göz önünde bulundurulduğunda eğitim verisinin boyutunun artması durumunda modelin tahmin doğruluğunun önemli seviyelerde artış gösterdiği

görülmektedir.

Elde edilen sonuçlar neticesinde en yüksek sınıflandırma doğruluğuna ulaşılan derin öğrenme modeli kullanılarak 19 Mayıs 2021 tarihinde çalışma alanında tespit edilen mülaj oluşumlarının dağılımını gösteren tematik harita üretilmiştir (Şekil IV). Çalışma alanının batı kesiminde, Körfezin kuzey ve doğusunda yer alan kıyı kesimlerinde yoğun mülaj oluşumları gözlenmiştir. Toplamda yaklaşık 210 km<sup>2</sup>'lik kısmında mülaj oluşumları gözlenmiştir. Bununla birlikte yalnızca yüksek yoğunluktaki mülaj oluşumlarının değil aynı zamanda orta ve düşük yoğunlukta olarak nitelendirilebilen formasyonların da derin öğrenme modeli tarafından tespit edildiği görülmüştür.



Şekil IV. En Yüksek Genel Doğruluk Oranına Sahip Derin Öğrenme Modeli İçin Üretilen Tematik Harita.

Çalışma kapsamında, son dönemin popüler teknolojisi yapay zeka tabanlı derin öğrenme tekniklerinin uzaktan algılanmış veri setleri kullanılarak mülaj formasyonlarının tespitindeki performansları incelenmiştir. Bu doğrultuda, farklı eğitim ve test veri seti boyutlarında oluşturulan beş farklı veri seti kullanılarak ESA tabanlı derin öğrenme modellerinin performansları analiz edilmiştir. Derin öğrenme modellerinin eğitim süreçlerinin ardından model performansları doğruluk analizi metrikleri kullanılarak nicel olarak değerlendirilmiştir. Elde edilen sonuçlar, eğitim veri seti boyutunun artışına paralel olarak derin öğrenme modelinin performansında önemli seviyelerde artışlar olduğunu göstermektedir. Buna karşın, eğitim veri seti boyutunun 10:90 olarak belirlenerek eğitilen derin öğrenme modelinin

performansının, eğitim veri seti boyutu 30:70 olarak belirlenerek eğitilen derin öğrenme modeline göre büyük bir artış sergilemesine rağmen ardından model doğruluğunun çok düşük artış göstererek neredeyse sabit kaldığı görülmektedir. Dolayısıyla, gelecek çalışmalarda gerçekleştirilen bu analizlerin farklı uzaktan algılanmış veri setleri, farklı derin öğrenme mimarileri ve parametre optimizasyonu süreçleri değerlendirilerek gerçekleştirilmesi gerekmektedir. Bunun yanı sıra çalışma kapsamında modellerinin performansları yalnızca su ve mülaj oluşumlarına yönelik pikseller kullanılarak değerlendirilmiştir. Dolayısıyla, gelecek çalışmalarda eğitilen derin öğrenme modellerinin farklı nesnelere de doğruluk analizine dahil edilerek modellerin hassasiyetinin değerlendirilmesine ihtiyaç duyulmaktadır.

## Kaynakça

- Acar, U., Yılmaz, O. S., Çelen, M., Ateş, A. M., Gülgen, F., & Şanlı, F. B. (2021). Determination of Mucilage in the Sea Of Marmara Using Remote Sensing Techniques with Google Earth Engine. *International Journal of Environment and Geoinformatics*, 8(4), 423-434.
- Colkesen, I., Kavzoglu, T., Sefercik, U. G., & Ozturk, M. Y. (2023). Automated Mucilage Extraction Index (AMEI): A Novel Spectral Water Index for Identifying Marine Mucilage Formations From Sentinel-2 Imagery. *International Journal of Remote Sensing*, 44(1), 105-141.
- Colkesen, I., Ozturk, M. Y., & Altuntas, O. Y. (2024). Comparative Evaluation of Performances of Algae Indices, Pixel-And Object-Based Machine Learning Algorithms in Mapping Floating Algal Blooms Using Sentinel-2 Imagery. *Stochastic Environmental Research and Risk Assessment*, 38(4), 1613-1634.
- Cozzi, S., Ivancic, I., Catalano, G., Djakovac, T., & Degobbi, D. (2004). Dynamics of the Oceanography Properties during Mucilage Appearance in the Northern Adriatic Sea: Analysis of the 1977 event in comparison to earlier events. *Journal of Marine Systems*, 50, 223-241. <https://doi.org/10.1016/j.jmarsys.2004.01.007>
- Esi, Ç., Ertürk, A., & Erten, E. (2024). Nonnegative Matrix Factorization-Based Environmental Monitoring of Marine Mucilage. *International Journal of Remote Sensing*, 45(11), 3764-3788.
- Hinton, G. E., and R. R. Salakhutdinov. (2006). Reducing the Dimensionality of Data with Neural Networks. *Science* 313 (5786): 504-507. [doi:10.1126/science.1127647](https://doi.org/10.1126/science.1127647).
- Hou, Y., Liu, Z., Zhang, T., & Li, Y. (2021). C-UNet: Complement UNet for Remote Sensing Road Extraction. *Sensors*, 21(6), 2153.
- Hu, K., Zhang, D., & Xia, M. (2021). CDUNet: Cloud Detection UNet for Remote Sensing Imagery. *Remote Sensing*, 13(22), 4533.
- Kattenborn, T., Leitloff, J., Schiefer, F., & Hinz, S. (2021). Review on Convolutional Neural Networks (CNN) in Vegetation Remote Sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 173, 24-49.
- Kaushal, A., Gupta, A. K., & Sehgal, V. K. (2024). A Semantic Segmentation Framework with UNet-Pyramid for Landslide Prediction using Remote Sensing Data. *Scientific Reports*, 14(1), 1-23.
- Kavzoglu, T., & Goral, M. (2022). Google Earth Engine for Monitoring Marine Mucilage: Izmit Bay in Spring 2021. *Hydrology*, 9(8), 135.
- Kavzoglu, T., Tonbul, H., Çölkesen, İ., & Sefercik, U. G. (2021). The Use of Object-Based Image Analysis for Monitoring 2021 Marine Mucilage Bloom in the Sea of Marmara. *International Journal of Environment and Geoinformatics*, 8(4), 529-536.
- Mishra, V. K., & Mishra, A. K. (2024). Mapping Phytoplankton and Algal Blooms with a Novel Multi Sensor Water Index (MSWI). *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*.
- Özalp, H. B. (2021). First massive mucilage event observed in deep waters of Çanakkale Strait (Dardanelles), Turkey. *Journal of the Black Sea/mediterranean Environment*, 27(1), 49-66.
- Schiaparelli, S., Castellano, M., Povero, P., Sartoni, G., Cattaneo-Vietti, R. (2007). A Benthic Mucilage event in North- Western Mediterranean Sea and its Possible Relationships with the Summer 2003 European Heatwave: Short Term Effects on Littoral Rocky Assemblages. *Marine Ecology*, 28(3), 341- 353.
- Sefercik, U. G., Colkesen, I., Kavzoglu, T., Ozdogan, N., & Ozturk, M. Y. (2024). Assessing the Physical and Chemical Characteristics of Marine Mucilage Utilizing In-Situ and Remote Sensing Data (Sentinel-1, -2, -3). *PFG-Journal of Photogrammetry, Remote Sensing and Geoinformation Science*, 92(4), 415-430.
- Sun, D., Gao, G., Huang, L., Liu, Y., & Liu, D. (2024). Extraction of Water Bodies from High-Resolution Remote Sensing Imagery Based on a Deep Semantic Segmentation Network. *Scientific Reports*, 14(1), 14604.
- Taş, S., Kuş, D., & Yılmaz, I. N. (2020). Temporal variations in Phytoplankton Composition in the North-Eastern Sea of Marmara: Potentially Toxic Species and Mucilage Event. *Mediterranean Marine Science*, 21(3), 668-683. <https://doi.org/10.12681/mms.22562>
- Wang, Q., Zhang, X., Chen, G., Dai, F., Gong, Y., & Zhu, K. (2018). Change Detection Based on Faster R-CNN for High-Resolution Remote Sensing Images. *Remote sensing letters*, 9(10), 923-932.
- Wasehun, E. T., Hashemi Beni, L., & Di Vittorio, C. A. (2024). UAV and Satellite Remote Sensing for Inland Water Quality Assessments: A Literature Review. *Environmental Monitoring and Assessment*, 196(3), 277.
- Xue, H., Liu, K., Wang, Y., Chen, Y., Huang, C., Wang, P., & Li, L. (2024). MAD-UNet: A Multi-Region UAV Remote Sensing Network for Rural Building Extraction. *Sensors*, 24(8), 2393.
- Yagci, A. L., Colkesen, I., Kavzoglu, T., & Sefercik, U. G. (2022). Daily Monitoring of Marine Mucilage Using the MODIS Products: A Case Study of 2021 Mucilage Bloom in the Sea of Marmara, Turkey. *Environmental Monitoring and Assessment*, 194(3), 170.
- Yılmaz, E. O., Tonbul, H., & Kavzoglu, T. (2024). Marine Mucilage Mapping with Explained Deep Learning Model Using Water-Related Spectral Indices: A Case Study of Dardanelles Strait, Turkey. *Stochastic Environmental Research and Risk Assessment*, 38(1), 51-68.
- Zhang, W., Tang, P., & Zhao, L. (2019). Remote Sensing Image Scene Classification Using CNN-CapsNet. *Remote Sensing*, 11(5), 494.
- Xu, H. (2006). Modification of Normalised Difference Water Index (NDWI) to Enhance Open Water Features In Remotely Sensed Imagery. *International Journal of Remote Sensing*, 27(14), 3025-3033.
- TÜİK (Türkiye İstatistik Kurumu). (2023). 2023 Adrese Dayalı Nüfus Kayıt Sistemi Sonuçları. <https://data.tuik.gov.tr/>