

PANORAMİK GÖRÜNTÜLER ÜZERİNDEN SU ALTI HEDEF TESPİTİ: DBSCAN VE DERİN ÖĞRENME AĞLARI İLE BÜTÜNLEŞİK BİR YAKLAŞIM

Fatma Kübra Akın Küçük¹
İTÜ, İstanbul

Prof. Dr. İbrahim Özkol²
İTÜ, İstanbul

ÖZET

Su altı hedef tespiti, deniz güvenliği, keşif ve denizcilik alanlarında kritik bir rol oynamaktadır. Fakat hedef tespit çalışmaları, deniz ortamının karmaşık ve doğal gürültülerle dolu olmasının bir sonucu olarak son derece zorlu bir alandır. Oluşan zorlukların üstesinden gelmek için yapılan birçok farklı geleneksel ve yenilikçi yöntem mevcuttur. Geleneksel su altı tespit yöntemleri, genellikle sınırlı alanlarda performans göstermekte, değişen ortam şartlarına uyum sağlamakta zorlanmakta ve panoramik bir bakış açısını yansıtmada yetersiz kalmaktadır. Su altı hedef tespiti alanında daha güvenilir sonuçlar elde etmek ve değişen ortam şartlarına uyum sağlayabilmek için yeni teknikler geliştirilmesi ihtiyacı oluşmuştur.

Bu çalışmada, DBSCAN (Density-Based Spatial Clustering of Applications with Noise) ve derin öğrenme ağlarının (yapay sinir ağlarının ve evrişimli sinir ağlarının) birleştirildiği yenilikçi bir yaklaşım sunulmuştur. Geliştirilen yaklaşımda sonar verilerinden oluşturulan panoramik deniz resimleri, ilk olarak DBSCAN algoritmasından geçirilmiş ve panoramadaki önemli veriler tespit edilmiştir. Oluşturulan veriler derin öğrenme ağlarına girdi olarak sağlanmış ve hedef tespiti yapılmıştır. Elde edilen sonuçlar derin öğrenme ağları ile eğitilen modellerinin sonuçları ile karşılaştırılmıştır. Geliştirilen bütünleşik yaklaşımın, sadece panoramik görüntülerle eğitilen modellerden, çok daha iyi performans gösterdiği ve hedef tespiti konusunda daha başarılı olduğu görülmüştür. Elde edilen sonuçlar, derin öğrenme ağlarının, DBSCAN tarafından belirlenen yoğunluklu alanlarda daha spesifik ve hassas özellikler öğrenerek su altı hedeflerini daha doğru bir şekilde tanıma yeteneğinin olduğunu göstermiştir.

GİRİŞ

Su altı akustik verileri, denizaltı savaşları, su altı hedef izleme, mayın tespiti, deniz güvenliği ve çeşitli su altı araştırmalarında anahtar bir rol oynayan önemli bir parametredir. Akustik veri toplama işlemi genellikle denizaltı mikrofonları, hidrofonlar veya sonar sistemleri gibi özel cihazlar kullanılarak gerçekleştirilir. Sonarlar, ses dalgalarının su altında yayılabilme etkisinden faydalanarak haberleşme, sualtının ve üstünün keşfi, hedef tespiti ve alan keşfi gibi birçok farklı alanda kullanılırlar.

Sualtı hedef tespiti, çeşitli sensörlerin, sonar sistemlerinin ve görüntüleme tekniklerinin kullanıldığı önemli bir faaliyet alanıdır. Kullanılan sensörler ve sonar sistemler su altındaki nesnelerden gelen ses dalgalarını algılar ve su altındaki cisimlerin tespiti için kullanılırlar. Sonar sistemlere sahip olan denizaltılar, torpidolar ve diğer su altı araçları düşman veya potansiyel tehditleri belirleme konusunda avantajlıdır. Son yıllarda su altı sistemlerinin gelişmesi ile birlikte hedef tespiti alanında yapılan araştırmalarda büyük bir artış meydana gelmiştir. Fakat, geniş su altı bölgelerindeki karmaşık topografyalar ve değişen çevresel koşulları nedeniyle su altı hedef tespiti kolay bir uygulama değildir ve çoğu zaman geleneksel tespit yöntemleri belirli bir alanda çalışmakta ve değişen çevre koşullarına uyum sağlamakta yeterli olmamaktadır.

Derin öğrenme yöntemleri, büyük veri setlerini analiz ederek öğrenme yeteneklerinden dolayı su altındaki karmaşık ortamlarda bile, akustik sensörlerden, su altı kameralarından ve diğer sensörlerden elde edilen büyük veri setlerini işleyerek, hedefleri tanımak, sınıflandırmak ve izlemek konusunda son derece etkili olmuştur.


Yapılan çalışmada, su altı hedef tespiti alanında DBSCAN ve derin öğrenme ağlarının beraber kullanıldığı yeni bir model ele alınacak ve geliştirilen modelde kullanılan veri seti, yöntem ve sonuçlardan bahsedilecektir.

YÖNTEM

Yöntem bölümünde kullanılan veri setinin oluşturulma aşamalarından ve geliştirilen modeldeki mimariden bahsedilecektir. Veri seti olarak simülasyon verileri kullanılmış olup, oluşturulan veri seti işlendikten sonra DBSCAN ve derin öğrenme ağlarından oluşan modele girdi olarak sağlanmıştır.

Veri Seti

Veri setinin oluşturulması: Yapılan çalışma kapsamında simülasyon ortamında oluşturulmuş sonar verileri ve beamforming algoritması kullanılarak açı, frekans ve gürültü seviyesinden oluşan panoramik su altı resimleri oluşturulmuştur. Beamforming algoritması ile işlenen sonar verileri, simülasyon ortamındaki çeşitli sensörlerden elde edilen bilgileri birleştirerek, belirli bir yönde odaklanmış ve güçlendirilmiş sinyallerle panoramik bir su altı resmi oluşturmuştur [Jiang, Wu, Huang, Xiao, 2022]. Oluşturulan resim, su altındaki detayları daha iyi anlamak ve nesneleri daha net bir şekilde görmek için kullanılmıştır. Şekil 1’de simülasyon ortamında oluşturulan farklı panoramik görüntüler bulunmaktadır. Şekil 1’de de görüldüğü üzere hedefin bulunduğu ve çevresindeki açı ekseninde gürültü seviyesi diğer açılara kıyasla daha yüksektir. Gürültü seviyesinin yüksek olması hedef tespiti için önemli bir bilgi sunar. Geliştirilen yaklaşımın test edilmesi için simülasyon ortamında hedefsiz, tek hedefli ve iki hedefli olmak üzere toplam 39 bin panoramik veri oluşturulmuş ve verilerin 33 bini eğitim, 6 bini ise test verisi olarak kullanılmıştır.



Şekil 1: Simülasyon Ortamında Üretilen Sağdan Sola Sırası İle Hedefsiz, Tek Hedefli Ve İki Hedefli Panorama Örnekleri

Veri setinin işlenmesi: Oluşturulan panorama resminde x ekseninde derece cinsinde açı değerleri, y ekseninde Hz cinsinden frekans verileri ve z ekseninde dB cinsinden gürültü seviyeleri bulunmaktadır. Veri seti oluşturulduktan sonra açı ve frekans bandındaki ölçek farklılığını ortadan kaldırmak için frekans ve açı eksenini normalize edilmiş ve iki eksen 0 ile 1 değerleri arasına getirilmiştir. Gürültü seviyesi değerleri ortam koşullarına göre çok çeşitli değerler almaktadır. Sakin deniz ortamında daha düşük gürültü seviyeleri oluşurken, hareketli deniz ortamında gürültü seviyesi değerleri artmaktadır. Ortam farklılıklarını ortadan kaldırmak ve gürültü seviyesindeki anlamlı verilerin kaybolmasını engellemek için normalizasyon yöntemi olarak z skor kullanılmıştır. Böylece hem tüm veriler birbirine yakın değerler arasına indirgenmiş, hem de anlamlı verilerin kaybı önlenmiştir. Z skor hesabı şu şekilde yapılmaktadır:

$$Z = \frac{x - \mu}{\sigma}$$

$$x = \text{Değer}$$

$$\mu = \text{Verilerin Ortalaması}$$

$$\sigma = \text{Verilerin Standart Sapması}$$

DBSCAN

DBSCAN algoritması, verilerin yoğunluk tabanlı bir şekilde kümeleme yapılmasına olanak sağlayan bir kümeleme yöntemidir [Moreira, Maribel, Carneiro, 2005]. DBSCAN, veri noktalarının yoğunluğu ve şekli konusunda önceden bilgiye ihtiyaç duymaz. Bundan dolayı küme sayısının ve şeklinin bilinmediği durumlarda avantaj sağlar. Algoritma girdi olarak ϵ (epsilon) ve MinPts parametrelerini alır. Epsilon, bir noktanın komşuluk yarıçapını belirtir. MinPts ise bir noktanın ϵ -yakınlığı içinde bulunması gereken minimum nokta sayısını belirtir [Ester, Kriegel, Sander, Xu,1996]. DBSCAN algoritması, geleneksel tespit yöntemlerinin ötesinde, gürültülü ortamlarda iyi performans gösterir ve hedeflerin doğal olarak oluşan yoğunluk bölgelerinde algılanmasına imkân tanır.

Derin Öğrenme

Derin öğrenme ağları, geniş ve detaylı panoramik görüntülerdeki karmaşık özellikleri öğrenme kabiliyetleri ile öne çıkar[Xue, Zhu, Xiao, Tong, Huang, 2020]. Çalışma kapsamında derin öğrenme yöntemlerinden yapay sinir ağları (ANN) ve evrişimli sinir ağları (CNN) mimarileri kullanılmıştır. CNN'ler, görsel tanıma problemleri için etkili olan derin öğrenme mimarileridir [Goodfellow, Bengio, Courville, 2016]. ANN'ler ise ses, görüntü, video, radyo frekansları ve diğer türlerdeki sinyallerin analizi, filtrelenmesi, sınıflandırılması ve işlenmesiyle ilgilenir [Xianlu, Wang, Qi, 2023]. Veri setleri iki model üzerinde test edilmiş ve sonuçlar değerlendirilmiştir. Oluşturulan ANN ve CNN mimarileri Şekil 2 ve 3'te gösterilmiştir.

```
CustomANN(
  (flatten): Flatten(start_dim=1, end_dim=-1)
  (fc1): Linear(in_features=16384, out_features=4096, bias=True)
  (ReLU3): ReLU()
  (fc2): Linear(in_features=4096, out_features=1024, bias=True)
  (ReLU1): ReLU()
  (fc3): Linear(in_features=1024, out_features=128, bias=True)
  (ReLU2): ReLU()
  (fc4): Linear(in_features=128, out_features=32, bias=True)
  (Sigmoid): Sigmoid()
)
```

Şekil 2: ANN Mimarisi

Panorama resimleri 3 boyutlu olduğunda tek boyutlu vektör haline getirmek için flatten işlemi uygulanmıştır. Ardından klasik ANN mimarisi oluşturulmuştur. Çıktı olarak her açı eksenini için hedef var/ hedef yok tahmini yapılmıştır. Çıkış katmanında sigmoid aktivasyon fonksiyonu kullanılmıştır.

```
CustomCNN(
  (cnn): Sequential(
    (0): Conv2d(1, 16, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (1): ReLU()
    (2): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
    (3): Conv2d(16, 32, kernel_size=(3, 3), stride=(1, 1), padding=(1, 1))
    (4): ReLU()
    (5): MaxPool2d(kernel_size=2, stride=2, padding=0, dilation=1, ceil_mode=False)
  )
  (fcc): Sequential(
    (0): Linear(in_features=32768, out_features=512, bias=True)
    (1): ReLU()
    (2): Linear(in_features=512, out_features=32, bias=True)
    (3): Sigmoid()
  )
)
```


Şekil 3: CNN Mimarisi

Önerilen Yaklaşım

Önerilen yaklaşımın akış şeması Şekil 4'de gösterilmiş olup akış şemasındaki adımlar sırasıyla takip edilmiştir.


Proje kapsamında ilk olarak simülasyon ortamında oluşturulan sonar verileri işlenmiş ve panoramik bir resim haline getirilmiştir. Ardından normalizasyon ve z skor hesaplamaları yapılmıştır. Uygun hali getirilen veriler DBSCAN algoritmasından geçirilmiştir. DBSCAN algoritmasına tüm panorama değerleri değil, her bir panorama için gürültü seviyesi (z skor değeri) sıfırdan büyük olan veriler verilmiştir. Bunun nedeni panorama resminde bulunan hedeflerin dB seviyeleri yüksektir ve

oluşturulan kümeler içinde hedef bulunan kümelerin dB seviyesinin yüksek olması beklenir. Bu nedenle dB seviyesi yüksek olan kümelere odaklanmak gerekir. Hem gereksiz veriler modele verilmeyerek model hızlandırılmış hem de sadece anlamlı veriler taşıyan kümelerin oluşması sağlanmıştır. DBSCAN tarafından kümeler oluşturulduktan sonra DBSCAN'ın kümeleme yapmadığı ve modele verilmeyen verilerin hepsinin dB seviyesi sıfır yapılmıştır ve böylece hedefin bulunduğu açılar daha belirgin hale getirilmiştir.



Şekil 4: Önerilen Yaklaşımın Akış Diyagramı

Şekil 5'te DBSCAN'den geçirilen panorama örnekleri bulunmaktadır. DBSCAN'den geçirilerek oluşturulan yeni panoramalar sırası ile ANN ve CNN modellerine girdi olarak verilmiş ve sonuçlar analiz edilmiştir.



Şekil 3: DBSCAN'den Geçirilen Panorama Resimleri

UYGULAMALAR VE DEĞERLENDİRME

Veri seti hazırlandıktan ilk olarak sadece aç ve frekans eksenleri normalize edilerek Şekil 2 ve 3'te gösterilen ANN ve CNN modellerine girdi olarak verilmiş, ardından gürültü seviyeleri de normalize edilerek eğitim tekrarlanmıştır. Önerilen yaklaşımın test edilmesi için veri setinde z skor hesaplamaları yapılmış ve DBSCAN algoritmasından geçirilip, ANN ve CNN modeline girdi olarak verilmiştir. Ayrıca kıyaslama yapmak için z skor hesaplaması yapıp DBSCAN'den geçirilmeyen veriler ile de eğitimler yapılmıştır.

Yapılan eğitimlerin sonuçları Tablo 1'de gösterilmiştir ve z skor hesaplamasının sonuçları iyileştirdiği görülsede de hem ANN hem de CNN modelinde en iyi sonucu önerilen yeni modelin vermiştir.

Tablo 1: Eğitim ve Test Sonuçları

		Ham Veriler	Normalize Edilmiş Veriler	Z Skor Hesaplaması Yapılan Veriler	DBSCAN'den Geçirilen Veriler
ANN	Eğitim Hatası	0.0698	0.0537	0.0186	0.0166
	Test Hatası	0.0725	0.0541	0.0261	0.0231
CNN	Eğitim Hatası	0.0604	0.0580	0.0332	0.0317
	Test Hatası	0.0583	0.0584	0.0361	0.0321

SONUÇ

Yapılan çalışma kapsamında su altı hedef tespiti yapmak için DBSCAN ve derin öğrenme ağlarının birlikte kullanıldığı yeni bir yaklaşım önerilmiştir. İlk olarak oluşturulan simülasyon verileri normalize edilmiş ve DBSCAN algoritmasından geçirilmiştir. Oluşturulan yeni veri setleri derin öğrenme modellerine verilerek sonuçlar analiz edilmiştir ve hem eğitim hem de test hatalarının en düşük olduğu model elde edilmiştir. Ham eğitim verileri ile kıyaslandığında ANN modeli için %76'lık, CNN modeli içinse %45'lik bir iyileşme elde edilmiştir. Parametre optimizasyonu yapılarak mevcut iyileştirme miktarının artması beklenmektedir. Elde edilen sonuçlar aynı zamanda derin öğrenme ağlarının DBSCAN algoritması ile spesifik ve hassas özellikler öğrenerek su altı hedef tespitinde daha iyi başarı performansı olduğunu göstermiştir.

Kaynaklar

- Ester, M., Kriegel, H. P., Sander, J., & Xu, X., 1996. A densitybased algorithm for discovering clusters a density-based algorithm for discovering clusters in large spatial databases with noise. Proceedings of the Second International Conference on Knowledge Discovery and Data Mining, Portland.
- Goodfellow, I., Bengio, Y., Courville, A., 2016. Deep Learning, 1 st ed., MIT Press, Cambridge, MA, USA.
- Jiang, J., Wu, Z., Huang, M., & Xiao, Z. ,2022. Detection of underwater acoustic target using beamforming and neural network in shallow water. Applied Acoustics, 189, 108626.
<https://doi.org/10.1016/j.apacoust.2021.108626>
- Moreira, A., Maribel, Y.S., Carneiro, S., 2005. Density-Based Clustering Algorithms-DBSCAN and SNN. University of Minho, Portugal.
- Xianlu, P., Wang, Y., Qi, Y., 2023. Artificial Neural Network Model and Its Application in Signal Processing. Asian Journal of Advanced Research and Reports. 17. 1-8. 10.9734/AJARR/2023/v17i1459.
- Xue, J., Zhu, J., Xiao, J., Tong, S., & Huang, L., 2020. Panoramic convolutional long short-term memory networks for combat intension recognition of aerial targets. IEEE Access, vol. 8, pp. 183312–183323.