

# Metrik Öğrenme Yöntemiyle Deniz Platformu Konumlarının Radar ve Optik Görüntüler Üzerinden Tahmin Edilmesi

## Ship Location Estimation from Radar and Optic Images using Metric Learning

Muhammed Maruf KILIÇ<sup>a, b</sup>

<sup>a</sup> TÜBİTAK, BİLGEM

41470, Kocaeli, Türkiye

maruf.kilic@tubitak.gov.tr

Yusuf Sinan AKGÜL<sup>b</sup>

<sup>b</sup> Bilgisayar Mühendisliği Bölümü

Gebze Teknik Üniversitesi, Kocaeli, Türkiye

akgul@gtu.edu.tr

**Özetçe**— Yerküresel konumlandırma sistemleri (YKS, İng. GPS), deniz araçlarının konumlarının belirlenmesi için kullanılmaktadır. Yerküresel konumlandırma sistemleri diğer sistemlere göre daha hassas, güvenilir ve pratiktir. Ancak bu sistemler kullanım durumunda dışarıdan gelecek saldırılara karşı güvenilir değildir. Bu sebepten dolayı kritik durumlarda bu yöntem kullanılamaz. Bu çalışmada deniz araçlarının radar görüntülerinden doğrudan veya uydu görüntüleri kullanarak girdi görüntüler arasındaki benzerlik metriğini öğrenerek konumu tahmin eden bir yöntem önerilmiştir. Görüntü işleme dünyasında son yıllarda derin öğrenme yöntemleriyle birlikte pek çok zorlu problemde yüksek başarımlar elde edilmiştir. Derin öğrenme yöntemlerinin diğer problemler üzerinde başarılı olmasından dolayı, konumlandırma probleminin çözümünde de derin metrik öğrenme yöntemi üzerine kurulu bir sistem hedeflenmiştir. Çalışma sonucunda elde edilen başarılar ümit vericidir. Bu çalışmaların geliştirilerek endüstriye kazandırılması hedeflenmektedir.

**Anahtar Kelimeler** — Derin öğrenme yöntemleri, Sınıflandırma, Konum tespiti, Deniz araçları, Metrik öğrenme, Radar görüntüleri, Uydu görüntüleri

**Abstract**— Global Positioning Systems (GPS) are used for obtaining the location of vessels. Global Positioning Systems, compared to the other systems are more precise, trustable and practical. However, using this system is not secure against outside attacks thus it can't be employed on critical situations. In this study, an alternative solution which predicts the location of vessels by processing input images of vessels, such as radar images, actual images or satellite images, to train system on similarity metric has been offered. Image processing world in recent years has been achieving an unbelievable success on many difficult problems by utilizing deep learning methods. Due to the success deep learning has on other problems, it had been aimed to produce a system employing deep learning methods on metric learning for solving positioning problems as well. The successful results obtained from this study are indeed promising. It's aimed to develop these studies further and present them for the use of industry.

**Keywords** — Deep Learning, Classification, Ship Locating, Metric Learning, Radar Images, Satellite Images

### I. GİRİŞ

Deniz araçlarının konumlarının belirlenmesi problemi çok eski bir problemdir. Çok yakın zamana kadar deniz araçlarının konumları, yerleri bilinen kara noktalarının gözlemlenmesi ve gökyüzü nesnelere beklenen zamandaki konumlarıyla karşılaştırılması gibi yöntemlerle belli bir hassasiyete kadar hesaplanmıştır. Daha sonraları, Atalet Tabanlı Seyrüsefer Sistemleri (ATSS, İng. inertial navigation systems) daha güvenli konum bulmak için kullanılmaya başlanmıştır. Günümüz dünyasının en sık kullanılan konumlama sistemi ise uydu ağı tabanlı yerküresel konum bulma sistemidir (YKS, İng. GPS).

YKS sistemlerinin oldukça avantajlı tarafları vardır. Bunlardan en başta geleni konum bilgilerinin hassas ve doğru şekilde üretilmesi, bu bilgilerin üretilmesi için gereken bilgisayar donanımının kolay elde edilebilmesi ve çok geniş bir alan içerisinde sorunsuz çalışması sayılabilir. Fakat YYS sistemlerinin bazı durumlarda kullanılmasını engelleyecek problemleri de mevcuttur. Bu sistemin uydudan aldığı sinyallerin çok zayıf olması ve kolayca engellenebilmesi, YYS'nin kullanım alanlarını kısıtlamaktadır. Özellikle askeri amaçlı kullanımlar için bu sistemin dışa bağımlı olması, kritik görevler için önemli dezavantajlar oluşturmaktadır.

Bu çalışmada YYS sistemlerinin kullanılmayacağı durumlar için görüntü tabanlı bir konum tespit mekanizması yapılması hedeflenmektedir. Bu sistemin hedefleri arasında, YYS'ye alternatif sistemlerin yapılabilirliğinin gösterilmesi, YYS bağımlılığını azaltacak bir sistem olması ve en az ATSS kadar dışarıdan gelecek saldırılara karşı dayanıklı olması yer almaktadır. Literatürde kullanılan kaba kuvvet yaklaşımlarından ve özellikle [5]'de sunulan radar ve uydu görüntülerinin eşleştirilmesinden farklı olarak, doğrudan radar görüntüleri kullanarak veya radar ve uydu görüntülerinin birlikte kullanılmasıyla aralarındaki benzerlik metriğini öğrenmeyi hedefleyen derin öğrenme üzerine kurulu bir yöntem önerilmiştir. Genel sistem mimarisi Şekil 1'deki gibidir.

### III. SUNULAN YÖNTEM

Radar ve harita görüntülerinden konum tespiti problemi sınıflandırma problemi olarak ele alan bir yöntem önerilmektedir. Burada hedeflenen görüntüler arasındaki benzerlik metriğinin öğrenilmesidir. Önerilen yöntem içerisinde doğrudan radar görüntülerinden veya radar ve uydu görüntülerinin birlikte kullanılmasıyla gerçekleşen iki bölüm bulunmaktadır. Birinci bölümde veri kümesi içerisinde yer alan herhangi bir görüntü ön işleme tabi tutularak aralarındaki gerçek dünya uzaklıklarını referans olarak etiketleme işlemi yapılır. Sonrasında yeni bir radar görüntüsü geldiğinde kümede yer alan bütün görüntüler ile ön işleme tabi tutulur sonuç bulunur. Harita görüntülerinin kullanıldığı ikinci bölümde ise ön işleme harita bilgileri de dahil olup girdi büyüklüğü artmakta ve eğitim bölümü biraz daha uzun sürmektedir.


Devam eden bölümlerde öncelikli olan verinin toplanması (Bölüm III.A), bu bölümde verinin ne kadar olduğu, etiketlerinin ne olduğu, nasıl bir ön işleme tabi tutulduğu (Bölüm III.C) ve yöntemimizde kullandığımız derin öğrenme modeline (Bölüm III.B) ait bilgiler bulunmaktadır.

#### A. Veri Toplama

Radar görüntüleri SPx Cambridge Pixel Radar Simulator uygulamasından temin edilmiştir. Simulator içerisinde bölge olarak Marmara Bölgesi seçilmiştir. İki farklı veri kümesi oluşturulmuştur. Birinci veri kümesi 504 sınıftan ve 6025 görüntüden oluşmaktadır. İkinci veri kümesi ise 3346 sınıftan ve 40.075 görüntüden oluşmaktadır. Sınıf isimleri görüntünün ait olduğu enlem ve boylam değerleridir. Her bir sınıf içerisinde ortalama 10-12 adet görüntü bulunmaktadır. Bu görüntüler aynı koordinat noktasının 1-2 piksel değişmiş halidir.

Uydu görüntüleri ise Google haritalar servisinden temin edilmiştir. Yüksek çözünürlüklü uydu görüntüleri ticari olarak elde edilebilir [6]. Her bir radar görüntüsüne karşılık bir uydu görüntüsü olacak şekilde uydu veri kümesi oluşturulmuştur.

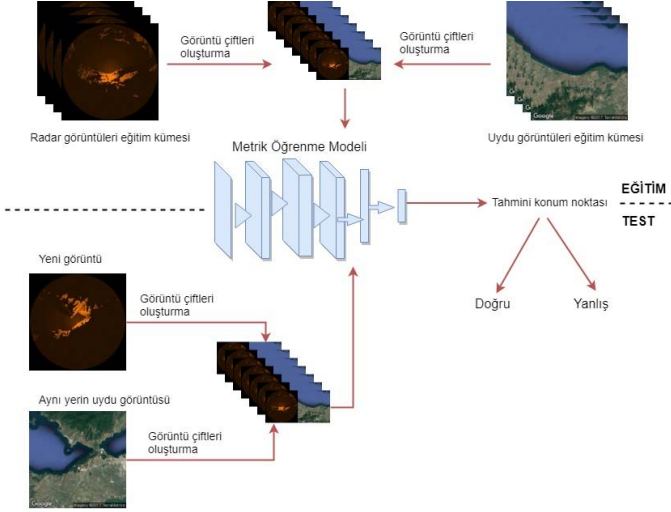
Aynı ve farklı koordinat değerlerine yani sınıflara ait radar ve uydu görüntüleri Şekil 2 ve Şekil 3'deki gibidir.



Şekil 2 Radar görüntüleri



Şekil 3 Uydu görüntüleri



Şekil 1 Genel sistem mimarisi

Bu bildirinin geri kalanında, benzer çalışmalar Bölüm II, verilerin toplanması Bölüm III.A, kullanılacak olan derin öğrenme modeli Bölüm III.B, verilerin ön işleme geçirilmesi Bölüm III.C, geliştirilen sistem üzerinde yapılan deneyler ise Bölüm IV anlatılmıştır. Elde edilen sonuçlar ve gelecek için yapılması planlanan çalışmalar ise Bölüm V yer almaktadır.

### II. ÖNCEKİ ÇALIŞMALAR

[1]'deki çalışmada temel olarak elektronik haritalar ve radar görüntüleri kullanılarak geminin konumunun bulunması üzerine bir öneride bulunulmuştur. Bu işlemin gerçekleştirilebilmesi için operatörün hem harita hem de radar üzerinde aynı noktaları işaretlemesi beklenmektedir. Operatörün bu işaretlemeyi ne kadar doğru yapabileceği soru işareti olmasından dolayı bu makalede önerilen yöntem pek tercih edilmemektedir. İki farklı görüntünün eşleştirilmesi yöntemlerinde genellikle Hausdorff uzaklığı veya onun varyansları kullanılmaktadır [3] ve bu yöntem radar ve uydu görüntülerinden konum tespiti için de kullanılmıştır. [2]. Hausdorff uzaklığını kullanarak şablon eşleştirme yönteminin aksine farklı bir yöntem mevcuttur. Bu yöntemde uydu görüntüsü ile radar görüntüsü doğrudan eşleştirilmemektedir. Belirlenen bir aday koordinat noktasına göre yapay radar görüntüsü oluşturulmaktadır. (Görüntü üzerinde boş kısımlar yok, öyle ki aday koordinat noktasına yakın olan kısımlar parlak uzak olan kısımlar mat bir şekildedir.) Oluşturulan yapay radar görüntü ile mevcut radar görüntüsünün eşleştirilmesi ve bu şekilde koordinatın bulunması öngörülmüştür [5].

Görüntü üzerinden doğrudan konum tespit eden çalışmalar bulunmaktadır [4]. Tüm dünyayı küçük parçalara ayırıp ve bu parçalara ait olan görüntüleri ilgili parçalar ile etiketleyip eğitim yapılmaktadır. Yaklaşık 150 milyon görüntü ile yapılan çalışmalar sonuçta görüntü haricinde herhangi bir bilgi olmaksızın il veya ülke bazında konum tespit edilebilmektedir. Siyam ağlar [7] ve üçüz ağlar [8] kullanılarak görüntüler arasındaki benzerlik metriğinin öğrenilmesi yoluyla sınıflandırma yapan yöntemler bulunmaktadır [9].

## B. Model

Radar görüntüleri doğrudan veya uydu görüntüleri ile birlikte ön işlemeden geçirildikten sonra problem sınıflandırma problemi olarak ele alınmaktadır. Tablo 1’de detayları bulunan model sınıflandırma problemi için kullanılmıştır. Etiketleme işlemi yaparken görüntüler arasındaki gerçek dünya uzaklıklarına göre 0 ile 9 arasında etiketleme yapıldı.

Çok fazla veri olmamasından ve mevcut veriler arasında benzerliğin yüksek olmasından dolayı modelin ezberlemesini önlemek amacıyla 0.25 ve 0.5 dropout katmanı kullanılmıştır. Bu sayede modelin ezberleme olasılığı ortadan kaldırılmak istenmektedir.

Tablo 1: Sınıflandırma için kullanılan ağ modeli

Input $128 \times 128$ Gray-Scale image
$3 \times 3$ conv. 32 ReLU
$3 \times 3$ conv. 64 ReLU
$2 \times 2$ max-pooling
Dropout 0.25
128 Dense ReLU
Dropout 0.5
10 softmax

## C. Ön İşleme

Radar ve uydu görüntüleri kendi içlerinde 3346 farklı sınıftan oluşmaktadır. Bu görüntülerin yalnız başlarına kullanılması faydalı değildir. Onun yerine bu görüntülerin birbirleriyle olan ilişkilerinin tespit edilip, modelin ona göre eğitilmesi gerekmektedir.

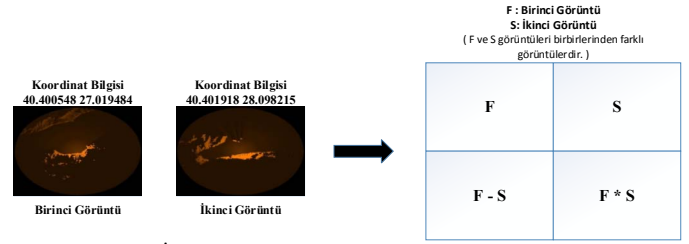
Tekli olan görüntüleri birbirleri ile kombine ederek aralarındaki ilişkinin öğrenilerek, yeni bir görüntü geldiğinde mevcut görüntüler içerisinde en çok hangisine yakın olduğunu tespit edilmek istenmektedir. Belirli bir bölgede yalnızca bir defa veri toplanması durumunda sistemin başarılı çalıştığını göstermeyi hedeflenmektedir.

Radar ve uydu görüntülerini sınıflandırma problemi olarak ele almak istediğimizde bu görüntülerin yeniden etiketlenmesi aşamasında Tablo 2’den yararlanılmaktadır. Gerçek dünyadaki 7 km’lik mesafe görüntü üzerinde 1 piksele karşılık gelmektedir.

Tablo 2 Görüntülerin gerçek dünyadaki aralarındaki uzaklık göz önünde bulundurularak etiketlenmesi

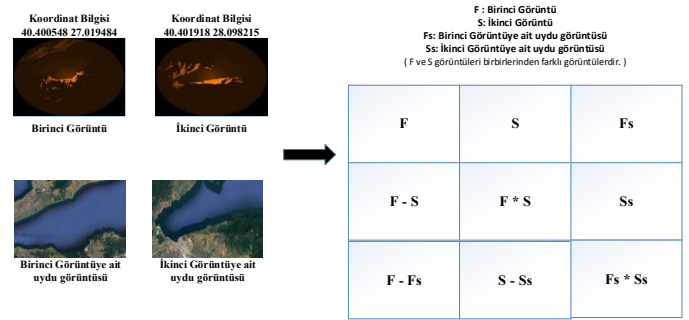
İki görüntü arasındaki gerçek uzaklık (kilometre)	Etiket
0 – 10	0
10 – 20	1
20 – 30	2
30 – 40	3
40 – 60	4
60 – 80	5
80 – 100	6
100 – 120	7
120 – 140	8
140 – $\infty$	9

Radar görüntüleri arasındaki ilişkinin öğrenilebilmesi için görüntülerin modele tekli olarak değil de Şekil 4’de görüldüğü gibi girdi verilmiştir. Buradaki amaç iki görüntü arasında ilişkinin kurulmasını sağlamaktır. İki görüntünün kendileri ve birbirleriyle olan farkları ve çarpımları tek bir görüntü olarak birleştirilip model eğitimi o şekilde yapılmıştır.



Şekil 4 İkili radar görüntüsünün nasıl oluştuğuna dair şekil

Radar görüntüleri arasındaki ilişkiye ek olarak aynı görüntülerin uydu görüntüleri eklenerek modele  $192 \times 192$  lik görüntüler ile eğitilmiştir (Şekil 5). Uydu görüntülerinin eklenmesiyle birlikte daha fazla bilgi olmasından dolayı karmaşıklık yaratmış ve başarımları düşürmüştür.



Şekil 5 Radar ve uydu görüntülerinin ilişkili olarak ifade edilmesi

## IV. DENEYLER

Radar ve uydu görüntüleri işlem öncesinde bir ön işlemden geçirilerek birbirleriyle ilişkilerinin öğrenilebilmesi için ikili (Şekil 4) veya dördü (Şekil 5) görüntü çiftleri oluşturulmaktadır. Radar ve uydu görüntülerinin sınıflandırılmasında konvolüsyonel sinir ağları kullanılmıştır. Ağ yapısı Tablo 1’deki gibidir.

Deneylerde iki farklı veri kümesi kullanılmaktadır. Veri kümelerine ait bilgiler Bölüm III.A Veri Toplama bölümünde anlatılmaktadır. 504 sınıftan oluşan veri kümesi sonuçlar tablosunda 1 olarak, 3346 sınıftan oluşan veri kümesi ise 2 olarak adlandırılmaktadır.

Deniz araçlarının konumlarının tespiti için sunulan yöntem ile yapılan deneylerde gözlemlenen sonuçlar umut vericidir. Bu deneyler farklı referans anlarında (İng. Epok), farklı veri kümeleriyle ve bu veri kümelerinden farklı sayıda ikililer oluşturularak gerçekleştirilmiştir.

Yapılan deneyler iki farklı açıdan ele alınmıştır. Bunlardan ilki yalnızca radar görüntülerinin yer aldığı deneyler, diğeri ise radar ve uydu görüntülerinin birlikte modele girdi olarak verildikleridir. Yalnızca radar görüntülerinin yer aldığı deneylerde ise test kümesi k katlamalı çapraz doğrulama yöntemiyle ayrılarak yapılan deneyler ve doğrudan farklı bir veri kümesi ile yapılan testler olmak üzere iki pencereden ele alınmaktadır.

Deneylerde, sistem tarafından doğru ve hatalı tespit edilen örnekler, görüntülerin gerçekte olan konumları, aralarındaki uzaklık (km) ve sistem tarafından yapılan hatanın piksel

cinsinden karşılığı ile birlikte Şekil 6 ve Şekil 7’de görülmektedir.



Şekil 6 Doğru Örnekler



Şekil 7 Hatalı Örnekler

Yalnızca radar görüntüleri kullanıldığında sonuçlar Tablo 3’deki gibidir. 1 numaralı veri kümesinin kullandığı deneylerde doğruluk değerinin çok daha yüksek, 2 numaralı veri kümesinin kullanıldığı deneylerde ise doğru değeri bir hayli düşmektedir. Bunun sebebi, 1 numaralı veri kümesinin daha küçük bir alanı işaret ediyor olmasından kaynaklıdır. 2 numaralı veri kümesi içerisinde 3346 sınıf bulunmakta, 1 numaralı veri kümesi içerisinde ise 504 sınıf bulunmaktadır. Tablodan da görüleceği üzere sınıf sayısı arttıkça başarımlar düşmektedir. Aynı veri kümelerinin kullanıldığı deneylerde ise eğitim veri sayısının artmasıyla birlikte doğruluk değerinin arttığı gözlemlenmektedir.

Tablo 3 Radar görüntülerinin deney sonuçları

Doğruluk Değeri	Ortalama Piksel Hatası	Eğitim Veri Sayısı	Test Veri Sayısı	Epok	Veri Kümesi
0.9678	-	40.320	8940	30	1
0.9608	-	40.320	8940	20	1
0.9628	-	40.320	8940	10	1
0.9545	0.1429	25.200	25.200	10	1
0.9694	0.0896	25.200	25.200	20	1
0.9686	0.0882	25.200	25.200	30	1
0.6973	0.7943	133.840	30.670	10	2
0.7210	0.7089	160.608	36.804	10	2
0.7672	0.6390	200.760	46.005	10	2

Radar ve uydu görüntülerinin birlikte kullanıldığı sonuçlar Tablo 4’deki gibidir. Tablodan da görüleceği üzere eğitim veri sayısının artması doğruluk değerini artırmaktadır.

Tablo 4 Radar ve uydu görüntülerinin deney sonuçları

Doğruluk Değeri	Ortalama Piksel Hatası	Eğitim Veri Sayısı	Test Veri Sayısı	Epok	Veri Kümesi
0.8556	0.1998	20.160	4640	10	2
0.9161	0.1109	40.320	9280	10	2
0.9204	0.0931	60.480	19200	10	2

Çalışmada Intel® Core™ i7 6700k işlemcili, 16 GB belleğe sahip, Nvidia GeForce GTX 1060 6GB ekran kartlı bir bilgisayar kullanılmıştır. 2 numaralı veri kümesinin 200 bin görüntü ile eğitimi 1,5 gün sürmektedir. Deneyler sonucunda eğitimde kullanılan veri sayısı arttıkça başarımın artacağı gözlemlenmiştir. Fakat eğitim süresinin çok uzun olmasından dolayı eğitimde kullanılan veri sayısı belirli bir seviyede kalmıştır.

## V. SONUÇLAR

Deneyler sonucunda gözlemlenen başarı sonuçları umut vericidir. Bu sonuçlardan görülüyor ki; bir defaya mahsus olmak üzere yeterli verinin toplanması durumunda GPS bağımlılığını azaltacak bir sonuç elde edilebilir. Burada hedeflenen açık denizde yer alan gemilerin konumlarının tespitinden daha çok kıyı veya kıyıya yakın yerlerde bulunan gemilerin konumlarının tespitidir. Kıyı kesimlerinde yıllar içerisinde çok fazla bir değişim olmayacağını (Dağların yıkılması vs.) varsayarak bir defa yapılan eğitim sonucunda uzun yıllar boyu kullanılabilir bir ürün ortaya çıkacaktır.

Radar simülasyon uygulamasından temin edilen görüntülerin çözünürlükleri yeteri kadar yüksek değildir. Bu çalışmanın devamında yüksek çözünürlüklü görüntülerin toplanmasıyla yeni bir veri kümesi oluşturulup mevcut sistemin başarımı gözlemlenecektir. Aynı zamanda daha performanslı donanım üzerinde eğitim veri kümesini artırıp başarımdaki değişim gözlemlenecektir. Devamında ise hedeflenen görüntüler arasındaki benzerliğin öğrenilmesi için derin öğrenme yöntemlerinden olan ikiz ağ (siyam) tabanlı [7] ve üçüz ağ tabanlı [8] yöntemlerin kullanılması olacaktır.

## BİLGİLENDİRME

Orhan Aksoy’a radar simülasyon görüntülerini bize sağladığı için teşekkür ederiz.

## KAYNAKLAR

- [1] A. Guesalaga, “Recursive estimation of radar biases using electronic charts”, *IEEE Transactions on Aerospace and Electronic Systems*, vol. 40, no. 2, pp. 725-733, 2004.
- [2] Torres-Torriti, M,” Automatic ship positioning and radar biases correction using the hausdorff distance”, 10th International Conference on Information Fusion, Quebec(Canada), 2007, pp. 1-8.
- [3] J. I. Olszewska and D. Wilson, “Hausdorff-distance enhanced matching of scale invariant feature transform descriptors in context of image querying”, in Proceedings of the IEEE International Conference on Intelligent Engineering Systems, June 2012, pp. 91-96.
- [4] T. Weyand, I. Kostrikov, and J. Philbin. PlaNet - Photo Geolocation with Convolutional Neural Networks. In European Conference on Computer Vision (ECCV), 2016
- [5] AE Aytac, O Aksoy, YS Akgul, “Ship positioning by matching radar images and map data”, 2014 22nd Signal Processing and Communications Applications Conference(SIU),pp 1423-1426 •
- [6] Digital Globe, Inc. Internet: www.digitalglobe.com
- [7] S. Chopra, R. Hadsell, and Y. LeCun, “Learning a similarity metric discriminatively, with application to face verification,” in CVPR, 2005.
- [8] Hoffer, E., Ailon, N.” Deep metric learning using triplet network” In: International Conference on Learning Representations Workshop. (2015)
- [9] L. Yang and R. Jin, “Distance metric learning: A comprehensive survey,” Michigan State University, vol. 2, no. 2, 2006.