

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

METRİK ÖĞRENME YÖNTEMİYLE
DENİZ PLATFORMU KONUMLARININ RADAR VE OPTİK
GÖRÜNTÜLER ÜZERİNDEN TAHMİN EDİLMESİ

MUHAMMED MARUF KILIÇ
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

GEBZE
2018

T.C.
GEBZE TEKNİK ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

METRİK ÖĞRENME YÖNTEMİYLE
DENİZ PLATFORMU KONUMLARININ
RADAR VE OPTİK GÖRÜNTÜLER
ÜZERİNDEN TAHMİN EDİLMESİ

MUHAMMED MARUF KILIÇ
YÜKSEK LİSANS TEZİ
BİLGİSAYAR MÜHENDİSLİĞİ ANABİLİM DALI

DANIŞMANI
PROF. DR. YUSUF SİNAN AKGÜL

GEBZE
2018

T.R.
GEBZE TECHNICAL UNIVERSITY
GRADUATE SCHOOL OF NATURAL AND APPLIED SCIENCES

SHIP LOCATION ESTIMATION
FROM RADAR AND OPTIC IMAGES
USING METRIC LEARNING

MUHAMMED MARUF KILIÇ
A THESIS SUBMITTED FOR THE DEGREE OF
MASTER OF SCIENCE
DEPARTMENT OF COMPUTER ENGINEERING

THESIS SUPERVISOR
PROF. DR. YUSUF SİNAN AKGÜL

GEBZE
2018

GTÜ Fen Bilimleri Enstitüsü Yönetim Kurulu'nun 20 / 06 / 2018 tarih ve 2018 / 32 sayılı kararıyla oluşturulan jüri tarafından 26 / 06 / 2018 tarihinde tez savunma sınavı yapılan MUHAMMED MARUF KILIÇ 'ın tez çalışması BİLGİSAYAR MÜHENDİSLİĞİ Anabilim Dalında YÜKSEK LİSANS tezi olarak kabul edilmiştir.

JÜRİ

ÜYE

(TEZ DANIŞMANI) : PROF. DR. YUSUF SİNAN AKGÜL

ÜYE

: DOÇ. DR. ERCHAN APTOULA

ÜYE

: DR. ÖĞR. ÜYESİ AYŞE BETÜL OKTAY

ONAY

Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Yönetim Kurulu'nun

...../...../..... tarih ve/..... sayılı kararı.

ÖZET

Deniz araçlarının konumlarının belirlenmesinde yaygın biçimde yer küresel konumlandırma sistemleri (YKS, İng. GPS) kullanılmaktadır. Yer küresel konumlandırma sistemleri diğer sistemlerden daha güvenilir, hassas ve pratik olduğundan dolayı yaygın olarak kullanılmaktadır. Fakat bu sistemler dışarıdan gelebilecek saldırılara karşı güvenilir değildir. Bu sebepten dolayı kritik durumlarda bu sistemin kullanılması sakıncalıdır.

Tez çalışması kapsamında görüntü işleme algoritmaları ve yöntemleri kullanılarak gerçek dünyadaki deniz araçlarının konumunun tahminin yapılması problemine bir çözüm yöntemi önerilmiştir. Bu problemin çözümünde son yıllarda görüntü işleme dünyasında pek çok zorlu problemde yüksek başarımlar elde eden derin öğrenme yöntemleri kullanılmaktadır. Deniz araçlarının konumlarının tespiti / tahmini problemi sınıflandırma problemi olarak ele alınmış ve çözümünde görüntüler arasında benzerlik metriği kullanılmıştır. Konum tahmininin yapılabilmesi için deniz araçlarına ait radar sinyallerinin iki boyutlu olarak renkli veya siyah-beyaz görüntüleri ile aynı noktadaki radar görüntüsüne karşılık gelecek uydu görüntüsüne ihtiyaç vardır. Radar ve uydu görüntüleri arasındaki benzerlik metriğinden yola çıkarak verilen bir görüntünün konumunu yaklaşık olarak tespit / tahmin edebilmektedir.

Deniz araçlarının konumlarının tespitinde doğrudan radar görüntüleri de kullanılabilir. Radar görüntülerinin doğrudan kullanıldıkları durum ve uydu görüntüleri birlikte kullanıldıkları durumları içeren deneyler yapılmış ve sonuçlar raporlanmıştır. Elde edilen başarılar ümit vericidir. Bu çalışmanın geliştirilerek endüstriye kazandırılması ve Türkiye Cumhuriyeti Türk Silahlı Kuvvetleri envanterinde yer alan deniz araçlarında kullanılması hedeflenmektedir.

Anahtar Kelimeler: Derin Öğrenme Yöntemleri, Konum Tespiti, Deniz Araçları, Metrik Öğrenme, Radar ve Uydu Görüntüleri.

SUMMARY

Global Positioning Systems 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 is unfavorable to employe this system on critical situations.

Within the scope of this thesis study a solution to the problem of location prediction of vessels in real world by utilizing image processing algorithms and techniques has been offered. For the said solution, deep learning methods which has been achieving an unbelievable success on many difficult problems in the image processing world has been used. Here, the problem of position detection and prediction of sailing vessels had been discussed as a classification problem and similarity metric between images had been utilized for the solution. To conduct the position prediction, 2D radar signal images of sailing vessels, either in white and black or in color and satalite images from the same (coordinate) points as the radar images are needed.

On the process of calculating position detection of sailing vessels, radar images can also be used solitary. Both cases including solitary usage of radar images and combining them with satalite images had been tested and reported as promisingly successful. It's been aimed to develop this study even further and deliver it to both endustry and armed forces of the Republic of Turkey to have them exploit it for the sailing vessels in their inventory.

Key Words: Deep Learning, Ship Locatining, Metric Learning, Radar and Satellite Images.

TEŞEKKÜR

Başta, yüksek lisans eğitimimde ve akademik hayatımda desteğini ve yardımlarını hiçbir zaman esirgemeyip bilgisi ile bu çalışmanın oluşmasının yolunu açan danışmanım Prof. Dr. Yusuf Sinan AKGÜL'e,

Bütün çalışmam boyunca yanımda olan, bilgi ve tecrübelerini benimle paylaşan değerli arkadaşım Gökhan ÖZBULAK'a,

ve göstermiş olduğu desteklerinden dolayı sevgili eşim Tuğba KILIÇ'a en içten teşekkürlerimi sunarım.



İÇİNDEKİLER

	Sayfa
ÖZET	viii
SUMMARY	ix
TEŞEKKÜR	x
İÇİNDEKİLER	xi
SİMGELER VE KISALTMALAR DİZİNİ	xiii
ŞEKİLLER DİZİNİ	xiv
TABLOLAR DİZİNİ	xvi
1. GİRİŞ	1
1.1. Tezin Amacı, Katkısı ve İçeriği	3
2. KONUM TAHMİN YÖNTEMLERİ	7
2.1. Sınıflandırma	7
2.1.1 Konvolüsyonel Sinir Ağları	8
2.2 Metrik Öğrenme	10
2.2.1 İkiz Ağlar ile Metrik Öğrenme	11
2.2.2 Evrişimsel (Konvolüsyonel) Sinir Ağları ile Metrik Öğrenme	21
3. VERİ KÜMESİ	29
3.1 Veri Toplama (Radar Görüntüleri)	29
3.2 Veri Toplama (Uydu Görüntüleri)	31
4. DENEYLER	33
4.1 Evrişimsel (Konvolüsyonel) Sinir Ağları Kullanılarak Sınıflandırma	33
4.2 İkiz Ağlar Kullanılarak Metrik Öğrenme	35
4.3 Evrişimsel (Konvolüsyonel) Sinir Ağları Kullanılarak Metrik Öğrenme	37
4.3.1 Yön bilgisi olmaksızın konum tahmini	37
4.3.2 Yön bilgisi eklenerek konum tahmini	40
4.3.3 Artırımsal konum tahmini / iyileştirme	48
5. SONUÇLAR	52
6. ÖNERİLER	55
KAYNAKLAR	56

ÖZGEÇMİŞ

58

EKLER

59



SİMGELER ve KISALTMALAR DİZİNİ

Simgeler ve Açıklamalar

Kısaltmalar

ATSS	: Atalet Tabanlı Seyrüsefer Sistemleri
ESA	: Evrişimsel Sinir Ağları
GTÜ	: Gebze Teknik Üniversitesi
KB	: Kilobayt
KTM	: Konum Tahmin Modeli
MB	: Megabayt
SGD	: Stokastik Gradient Descent
YKS	: Yerküresel Konumlandırma Sistemleri

ŞEKİLLER DİZİNİ

<u>Şekil No:</u>	<u>Sayfa</u>
1.1: Ataletsel seyrüsefer sistemleri (ATSS).	1
1.2: Yerküresel konumlandırma sistemleri örnek.	2
1.3: Simülasyondan temin edilen örnek radar görüntüleri.	3
2.1: Evrişimsel Sinir Ağları kullanılan sınıflandırma modeline ait eğitim aşaması.	9
2.2: Evrişimsel Sinir Ağları kullanılan sınıflandırma modeline ait test aşaması.	10
2.3: İkiz Ağlar ile Metrik Öğrenmede görüntülerin etiketlenmesi.	11
2.4: Radar görüntülerinin girdi olarak alındığı İkiz Ağlar modelinin eğitim aşaması.	13
2.5: Radar ve uydu görüntülerinin girdi olarak alındığı İkiz Ağlar modelinin eğitim aşaması.	14
2.6: Radar görüntülerinin girdi olarak alındığı İkiz Ağlar modelinin test aşaması.	15
2.7: Radar ve uydu görüntülerinin girdi olarak alındığı İkiz Ağlar modelinin test aşaması.	16
2.8: Radar görüntülerinin girdi olarak alındığı ve içerisinde evrişimsel katmanlar içeren ikiz ağlar modelinin kullanıldığı eğitim aşaması.	18
2.9: Radar ve uydu görüntülerinin girdi olarak alındığı ve içerisinde evrişimsel katmanlar içeren ikiz ağlar modelinin kullanıldığı eğitim aşaması.	19
2.10: Radar görüntülerinin girdi olarak alındığı ve içerisinde evrişimsel katmanlar içeren ikiz ağlar modelinin kullanıldığı test aşaması.	20
2.11: Radar ve uydu görüntülerinin girdi olarak alındığı ve içerisinde evrişimsel katmanlar içeren ikiz ağlar modelinin kullanıldığı test aşaması.	21
2.12: Radar görüntüleri arasındaki ilişkinin öğrenilmesi için ön işlemden geçirilmesi.	23
2.13: Radar görüntüleri metrik öğrenme eğitim aşaması.	24
2.14: Radar görüntüleri metrik öğrenme test aşaması.	25

2.15:	Radar ve uydu görüntülerinin aralarındaki ilişkinin öğrenilmesi için önişlemden geçirilmesi.	26
2.16:	Radar ve uydu görüntüleri kullanılarak metrik öğrenme yapılması (Eğitim aşaması).	27
2.17:	Radar ve uydu görüntüleri kullanılarak metrik öğrenme yapılması (Test aşaması).	28
3.1:	Simülasyondan alınan ham radar görüntüleri.	30
3.2:	Simülasyondan alınan ham radar görüntüsü, sol alt köşede konum bilgileri yer almakta.	31
3.3:	Google haritalar servisinden indirilen örnek uydu görüntüsü.	32
4.1:	Doğru örnekler.	38
4.2:	Hatalı örnekler.	38
4.3:	Yön bilgisi eklenen sistemde görüntü etiketlenmesi.	40
4.4:	Yön bilgisi eklenerek konum tahmini test senaryosu.	42
4.5:	Yön bilgisi eklenerek konum tahmini Doğru Örnekler (1 piksel ve altındaki hatalar sistem için başarılı / doğru kabul edilmektedir.).	43
4.6:	Yön bilgisi eklenerek konum tahmini Hatalı Örnekler (1 piksel üstündeki hatalar sistem için başarısız /hatalı kabul edilmektedir.).	44
4.7:	X yönündeki örnek hata matrisi.	44
4.8:	Y yönündeki örnek hata matrisi.	46
4.9:	Artırımsal konum tahmini için yalnızca radar görüntülerinin kullanıldığı örnek test senaryosu.	49
4.10:	Artırımsal konum tahmini örnek test senaryosu.	50
5.1:	Sonuçlar Sınıflandırma örnek.	52
5.2:	Sonuçlar İkiz Ağlar örnek.	53
5.3:	Sonuçlar Evrişimsel katmanlı metrik öğrenme örnek.	54


TABLÖLAR DİZİNİ

<u>Tablo No:</u>	<u>Sayfa</u>
2.1: Sınıflandırma problemi çözümünde kullanılan evrişimsel katmanlı ağ yapısı	8
2.2: İkiz ağlar model.	12
2.3: İkiz ağlar evrişimsel model.	17
2.4: Sınıflandırma için kullanılan ağ modeli.	22
2.5: Görüntülerin gerçek dünyadaki aralarındaki uzaklık göz önünde bulundurularak etiketlenmesi.	24
4.1: Öğrenme katsayısının değiştirilerek test edilmesi.	33
4.2: Optimizasyon fonksiyonunun değiştirilerek test edilmesi.	34
4.3: Aktivasyon fonksiyonunu değiştirilerek gerçekleştirilmesi.	34
4.4: Yalnızca tam bağlı katmanlardan oluşan ikiz ağlar modelinin deney sonuçları.	35
4.5: Evrişim katmanları ile birlikte tam bağlı katmanlardan oluşan ikiz ağlar modelinin deney sonuçları.	36
4.6: Radar görüntülerinin deney sonuçları.	39
4.7: Radar ve uydu görüntülerinin deney sonuçları.	39
4.8: Yön bilgisi eklenerek konum tahmin modeli.	41
4.9: Yön bilgisi eklenerek konum tahmini deney sonuçları.	45
4.10: Yön bilgisi eklenerek konum tahmini deney sonuçları (Eğitim ve test kümesi tamamen farklı seçilmiştir. Aynı sınıftan herhangi bir görüntü bulunmamaktadır).	46
4.11: Artırımsal konum tahmini deney sonuçları.	51

1. GİRİŞ

Antik çağlardan günümüze kadar geçen sürede tüm denizcilerin ortak amacı hep aynı olmuştur: Denizde bir noktadan başka bir noktaya hızlı ve güvenilir bir şekilde ulaşmak. Eski yıllarda sabit kara cisimlerine bakarak veya gökyüzü cisimlerini referans alarak konum tespiti yapılırdı. Yakın yıllarda ise teknolojinin gelişmesiyle birlikte Atalet Tabanlı Seyrüsefer sistemleriyle (ATSS, İng. Inertial navigation systems) birlikte uydu ağı tabanlı yer küresel konum bulma sistemleri (YKS, İng. GPS) kullanılmaktadır.


Atalet Tabanlı Seyrüsefer sistemleri; çeşitli tipte jiroskopları, çok hassas mekanik ivmeölçerleri ve elektronik devre kartları ile konum tespitinde yardımcı olan sistemlerdir [1](Şekil 1.1). ATSS sistemleri dışarıdan müdahalelere karşı dayanıklıdır. Fakat doğruluk olarak çok güvenilir ve hassas değildir.



Şekil 1.1: Ataletsel Seyrüsefer Sistemleri (ATSS).

Uydu ağı tabanlı yer küresel konum bulma sistemleri; İçerisinde yaklaşık olarak otuzdan fazla uydu bulundurur. Bu uydular Dünya'nın çevresinde bir günde iki tam tur atarlar. Uyduların her biri radyo sinyalleri yayar. Bu sinyaller uyduların yörüngedeki konum bilgisini ve sinyalin gönderildiği zamanı içeren bilgi taşır. Bu

bilgi ise ışık hızında taşınır. YKS alıcıları, uyduların sinyali gönderdiği zamanla sinyali aldığı zaman arasındaki farkı hesaplar. Bu zaman farkını ışık hızıyla çarparak kendisinin uydulara olan uzaklığını belirler [2](Şekil 1.2). Aynı anda birçok uydudan alınan uzaklık bilgisiyle YKS alıcısı kendi konumunu bulur. YKS uyduları yeryüzünde bulunan yer istasyonlarından sürekli izlenir ve yörüngedeki konumları, zaman bilgilerinin doğruluğu kontrol edilir [3](Şekil 1.2). YKS sistemlerinin oldukça avantajları yönleri vardır. Bunlar; 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. Dezavantaj olarak ise sistemin uydudan aldığı sinyallerin çok zayıf olması ve kolayca engellenebilmesi, dışa bağımlı olması gösterilebilir. Özellikle askeri unsurlar için olası bir harp durumunda kullanılması çok tehlikeli olacaktır.




Şekil 1.2: Yerküresel Konumlandırma Sistemleri Örnek.

Bütün ülkelerin kendilerine ait konum belirleme uyduları olmadığından dolayı ve olası bir harp durumunda YKS kullanmanın tehlikeli olacağından dolayı farklı araştırmacılar farklı yöntemler kullanarak konum tahmini yapmak üzerine çalışmalar yapmaktadır. ABD, YKS sistemini askeri ve sivil kullanıma açmış olsa da politik riskleri sebebiyle Rusya tarafından GLONASS, Avrupa Birliği tarafından GALILEO, Çin tarafından BeiDou gibi bölgesel ve küresel uydu tabanlı milli konumlama sistemleri geliştirilmiştir. Ülkemizin küresel uydu tabanlı yerli ve milli bir konumlama sistemi bulunmamaktadır.

1.1. Tezin Amacı, Katkısı ve İçeriği

YKS ve ATSS sistemlerinin yanında hemen hemen tüm deniz araçlarında yer alan ve denizcilere yardımcı olan bir diğer sistemde radar sistemleridir. Radar sistemleri denizcilerin en önemleri yardımcılarında biridir. Gönderilen elektromanyetik dalganın, bir hedefe çarpması, geri yansımaları ve kaynağa tekrar geri ulaşması sonucu bir görüntü oluşturmaya "Radar" denir [4]. Kısacası radar, herhangi bir cismin görünebilirliğini sağlayan bir elektronik cihazdır. Radar teknolojisi 1900'li yılların başlarında keşfedilmiştir. Günümüzde ise tüm gemilerde yaygın olarak kullanılmaktadır. Radarlar, su üzerinde bulunan her türlü yüzen cisim göremezler. Gönderilen manyetik dalgaların metal gibi bir cisme çarpıp geri dönmesi gerekmektedir. O sebeple fiberden yapılan tekneler, ahşaptan yapılan tekneler, su üzerinde yüzen platformlar geri yansıma yapmadığı için radar ekranında görünmeyebilir. Radarın faydaları arasında; gece seyirlerinde, görüş mesafesinin düştüğü sisli günlerde yardım sağlaması gösterilebilir. Simülasyon uygulamasından alınan örnek radar görüntüleri Şekil 1.3'deki gibidir.



Şekil 1.3: Simülasyondan temin edilen örnek radar görüntüleri.

Tez kapsamında YYS sistemlerinin kullanılamayacağı durumlar için doğrudan radar görüntülerinin veya uydu görüntüleriyle ilişkisi üzerinden deniz araçlarının

konumlarının tespitini öngören metrik öğrenmeye dayalı görüntü tabanlı bir konum tespit mekanizması yapılması hedeflenmektedir. Bu sistemin, YKS'ye duyulan bağımlılığı azaltması hedeflenmektedir.


Radar görüntüleri ile birlikte elektronik haritalar kullanılarak geminin konumunun tahmin edilmesi üzerine çalışmalar yapılmıştır [5]. Bu çalışmada yarı otomatik bir sistem önerilmiştir. Operatörün hem harita hem de radar üzerinden aynı konumları işaretlemesi beklenmekte ve bu işaretlemeler doğru kabul edilip onun üzerinden konum tespiti yapılmaktadır. Burada operatörün yapabileceği hatalı veya hassas olmayan işaretlemeler sonucu önemli ölçüde etkilemektedir ve pek tercih edilen bir yöntem değildir. Doğrudan radar ve uydu görüntülerinin birbirleriyle karşılaştırılmasından [6] ve farklarının alınmasından [7] tespit edilen çalışmalar mevcuttur. Bu çalışmalarda uzaklık metriği olarak Hausdorf uzaklığı ve Hausdorff uzaklığının zayıf kaldığı kısımlarda onun varyansları tercih edilmiştir. Hausdorff uzaklığının kullanıldığı ve şablon eşleştirme yönteminin aksine farklı yöntemler de mevcuttur. Bu yöntemler de uydu görüntüsü ile radar görüntüsü doğrudan karşılaştırılmaksızın ama bir işlemde geçirilerek sonrasında karşılaştırılmaktadır. Hedeflenen doğrudan radar görüntüsünün uydu görüntüsü ile karşılaştırılmadan, uydu görüntüsü üzerinden seçilecek bir aday noktası için yapay bir radar görüntüsü oluşturmak ve bu oluşan yeni görüntü ile mevcut radar görüntüsünün karşılaştırılması üzerine dayanmaktadır. Normal radar görüntülerinde sinyalin ulaşmadığı kısımlar siyah olarak belirtilir fakat burada yapay radar üzerinde herhangi boş kısım bulunmamaktadır. Dolayısıyla şablon karşılaştırması işlemi daha başarılı olarak uygulanabilmektedir [8]. Diğer çalışmaların yanında görüntü üzerinden doğrudan konum tahmini yapan çalışmalar bulunmaktadır [9]. Bu çalışmada, tüm dünya küçük parçalara ayrılmıştır. Bu parçaların her birine bir etiket verilip ve bu parçalara ait olan görüntülerin aynı etiket altında birleştirilip eğitim yapılmıştır. Yeni bir görüntü geldiğinde sisteme sorularak konumu tahmin edilmektedir. Bu çalışma [9] yaklaşık olarak 150 milyon görüntü ile gerçekleştirilmiştir. Çalışmalar sonucunda görüntü haricinde farklı bir bilgi olmadan ülke veya şehir bazında konum tespiti yapılabilmektedir. [9] numaralı çalışma haricinde diğer tüm çalışmalarda eski yöntemler (derin öğrenme yöntemleri haricindeki yöntemler) kullanılmıştır. Derin öğrenme yöntemlerinin güncel problemler üzerindeki başarıları yüksektir. Bu problemlere ve onların çözümlerinde kullanılan yöntemlere örnekler verebiliriz. Görüntüden nesne tanıma ve sınıflandırma probleminde AlexNet [10] önerilmiştir.

AlexNet bir derin ağ modelidir. Eski yöntemlerle karşılaştırıldığında yüksek bir başarımla elde etmiştir.

Görüntüden nesne tanıma ve sınıflandırma haricinde otomatik cümle çeviri problemi de zor bir problemdir. Bu problemin çözümünde RNN [11] ve LSTM [12] modelleri yüksek başarımla elde etmiştir. Bu problem üzerinde de derin öğrenme yöntemleri eski yöntemlerle karşılaştırıldığında üstünlük sağlamıştır. Derin öğrenme yöntemlerinin kullanıldığı ve yüksek başarımla edildiği bir diğer problem otomatik el yazısı üretme problemidir [13]. Burada hedeflenen; el yazısı ile yazılmış metin verildiğinde o metnin yeni bir el yazısı ile yeniden yazmasıdır. Otomatik el yazısı üretme problemi yanında otomatik yazı üretme problemi de vardır [14]. Kelime kelime veya karakter karakter yeni bir tahmin yapması beklenmektedir [15].

Görüntüler arasındaki benzerlik metriğinin öğrenilmesi işlemine metrik öğrenme denir. Derin öğrenme yöntemleriyle bunun yapılmasına ise derin metrik öğrenme denir. İkiz ağlar [16] ve Üçüz ağlar [17] bu şekilde sınıflandırma yapan yöntemlerdendir.

Tez kapsamında yayınlanan bildiride [18] önerilen yöntem; radar görüntülerinin doğrudan veya radar görüntüleri ile uydu görüntülerinin birlikte kullanılmasıyla derin metrik öğrenme yöntemlerinin kullanılarak konum tahmini yapmasıdır. Genellikle derin metrik öğrenme yöntemlerini kullanırken ikiz ve üçüz ağlar kullanılmaktadır. Mevcut veri kümesi üzerinde ikiz ağlar kullanılarak deneyler yapılmıştır. Fakat sonuçlar başarılı değildir. Bu sebeple burada ikiz ağlar veya üçüz ağlar kullanılmamıştır. Onun yerine konvolüsyonel sinir ağları kullanılarak metrik öğrenmesi yapılmaktadır. Test aşamasında sisteme girdi olarak verilen görüntüye çıktı olarak eğitim kümesinde yer alan sınıflar içerisinde kendisine en yakın olan sınıf ve o sınıfa kaç piksel uzakta olduğudur. Fakat burada Kartezyen koordinat sisteminde x ve y yönünde ne kadar uzak olduğuna dair bir bilgi bulunmamaktadır. Bildirinin devamında yapılan çalışmalarda x ve y yönünde pozitif ve negatif tarafta olmak üzere ne kadar uzakta olduğuna dair bilgiler bulunmaktadır. Çok uzak bir nokta bulunması durumunda kendisini o noktaya yönlendirerek aynı işlem belirtilen eşik değeri uzaklığına ginceye kadar tekrarlanır. Bu şekilde daha doğru sonuç elde edilmek istenmiştir. Sistemin genel mimarisi Şekil 1.4'deki gibidir.



Şekil 1.4: Genel Sistem Mimarisi.

Ülkemizin küresel uydu tabanlı yerli ve milli bir konumlama sistemi bulunmamaktadır. YKS'nin kullanımında dışa bağımlılık mevcuttur. Tez kapsamında geliştirilen sistem bu bağımlılığın azaltılabileceğini göstermektedir. Tezin en büyük katkısı yerli bir ürünün ortaya çıkmasına önyak olacak bir fikir ile dışa bağımlılığının azaltılmasında görev almaktır. Bu çalışmanın devamında veri kümesinin büyütülmesi, hesaplama gücü dayı fazla bilgisayarların temini ve gerçek radar görüntüleri ile yüksek çözünürlüklü uydu görüntülerinin temini ile kapsam genişlettilererek daha genel bir çözüm sunulabilir.

2. KONUM TAHMİN YÖNTEMLERİ

Bu bölüm deniz araçlarının konumunun tahmini probleminde kullanılan ve önerilen yöntemler hakkında detaylı bilgi içermektedir.

2.1 Sınıflandırma ve 2.2 Metrik Öğrenme bölümlerinde önerilen yöntemlerdeki derin öğrenme modelleri içerisinde evrişim ve tam bağlı katmanları kullanılmaktadır. Evrişim doğrusal olmayan, tam bağlı ise doğrusal olan bir katmandır. Evrişim katmanı Evrişimsel Sinir Ağları (ESA)'nın temelini oluşturmaktadır. Evrişim katmanı dönüşüm katmanı olarak ta bilinir. Buradaki dönüşüm işlemi verilerin doğrusal uzaydan farklı bir uzaya taşınması olarak söylenebilir. Dönüşüm işlemi belirli bir filtrenin tüm görüntü üzerinde dolaştırılması işlemine dayanmaktadır. Buradaki filtreler 2x2, 5x5, 7x7 gibi farklı boyutlarda olabilir. Bu filtreler, bir önceki katmandan gelen görüntüler üzerinde evrişim işlemini uygulayarak çıktı oluşturur. Bu evrişim işlemi sonucu özellik haritası oluşur. Özellik haritası, her bir filtreye karşılık gelen özelliklerin keşfedildiği bölgelerdir.

2.1 Sınıflandırma bölümünde mevcut problemin sınıflandırma problemine benzetilerek, eldeki görüntüler üzerinde derin öğrenme yöntemlerinin kullanılabilirliğini öğrenmeyi amaçlayan yöntem anlatılmaktadır. 2.2 Metrik öğrenme bölümünde ikiz ağlar ve evrişimsel sinir ağlarının kullanıldığı yöntemler anlatılmaktadır. Metrik öğrenme bölümünde yer alan evrişimsel sinir ağlarının kullanıldığı yöntem tercih edilen asıl yöntemdir. Bu yöntemde kullanılan modellere ait katman bilgileri, filtre sayıları, girdi görüntüleri ve bu görüntülerin nasıl bir ön işlemden geçirildiği gibi bilgiler de anlatılmaktadır.

2.1. Sınıflandırma

Deniz araçlarının konumunun tespiti problemi sınıflandırma problemine benzetilerek ele alınmış ve çözümü için yöntem önerilmiştir. Bu bölümde önerilen yöntem ile alakalı yapılan çalışmalar ve kullanılan model bilgisine ait özellikler anlatılmaktadır.

2.1.1 Konvolüsyonel sinir ağları bölümünde problemin çözümünde kullanılan derin öğrenme ağ yapısı, öğrenme kısımlarının sorunlu olmaması için ezberlemenin nasıl engellenebileceği hakkında bilgi içermektedir.

2.1.1 Konvolüsyonel Sinir Ağları

Deniz araçlarının konumunun tespiti problemi sınıflandırma problemi olarak ele alınmıştır. Problemin çözümü için derin öğrenme yöntemlerinde kullanılan konvolüsyonel sinir ağları denenmiştir. Bu yöntemin tercih edilmesinin sebebi, problemin üzerinde derin öğrenme yöntemlerinin gözlemlenmek istenmesidir. Bu yöntemin avantajı uygulanması basittir. Dezavantajı ise konum tahmin problemini tam olarak çözememektedir. Sınıflandırma probleminin mevcut problem üzerinde tam olarak çalışabilmesi için konum aralıklarının çok sık olarak etiketlenmesi gerekmektedir. Yeni bir görüntü geldiğinde bu görüntü için tahmin edilen sınıf, eğitim kümesinde yer alan sınıflardan farklı değildir. Yani daha önce hiç görmediği bir sınıf olması durumunda veya eğitim için kullanılan görüntüler dışından yani bir daire çizmediği durumlarda hep bilinen bir değer tahmin edecektir. Bu şekilde bir kullanım bizim hedefimiz için uygun değildir.


Bu yöntemin bize sağladığı fayda, hazırlamış olduğumuz veri kümesi üzerinde derin öğrenme yöntemlerinin uygulanabildiğini ve başarımlar elde edebileceğimizin görülmesi olmuştur. Konvolüsyonel sinir ağları içeren modelin katmanlarına ait bilgiler Tablo 2.1’de görüldüğü gibidir.

2.1: Sınıflandırma problemi çözümünde kullanılan evrimsel katmanlı ağ yapısı.

Input 64×64 Gray-Scale image
3×3 conv. 64 ReLU
3×3 max-pooling
3×3 conv. 128 ReLU
2×2 max-pooling
3×3 conv. 256 ReLU
2×2 max-pooling
Dropout 0.25
512 FC ReLU
Dropout 0.25
3346 Softmax


Tablo 2.1’de yer alan modelin ilk katmanı girdi görüntülerinin olduğu katmandır. Model girdi olarak 64 x 64 boyutunda siyah-beyaz görüntü almaktadır. Görüntüden özniteliklerin çıkarılması için üzerinde iki, üç ve dördüncü katmanlarda evrişim (konvolüsyon) işlemi uygulanmıştır. Mevcut veri kümesi üzerinde daha fazla uygulanması durumları denenmiş fakat en iyi durum 3 tanesinin kullandığı durum olarak tespit edilmiştir. Devamında yer alan dropout işlemi ise ezberlemenin önlenmesi için tercih edilmiştir. Son katmanda ki 3346 değeri ise sınıf sayısını göstermektedir.

Sınıflandırma modelinin kullanıldığı eğitim aşaması şekilde görüldüğü gibi yapılmaktadır.



Şekil 2.1: Evrişimsel sinir ağıları kullanılan sınıflandırma modeline ait eğitim aşaması.

Elimizde toplamda 40.075 adet radar görüntüsü bulunmaktadır. Bu görüntüler yakınlıklarına göre bir sınıfta en az 10 ile 12 arasında görüntü bulunacak şekilde sınıflandırıldığında toplamda 3346 farklı sınıf oluşmaktadır. Burada yapılan eğitimde tüm küme üzerinden k katlamalı çapraz doğrulama (k-fold cross validation) yöntemiyle verinin %90 lık kısmı kullanılarak yani yaklaşık olarak 36. 000 görüntü ile testler gerçekleştirilmiş, geriye kalan 4 bin görüntü ile test edilmiştir. Test aşaması şekilde görüleceği gibidir.



Şekil 2.2: Evrişimsel sinir ağları kullanılan sınıflandırma modeline ait test aşaması.

Test görüntüsünün boyutu 64 x 64 olmalıdır. Daha büyük veya küçük olduğu durumlarda görüntü boyutu 64 x 64 olarak ayarlanmalıdır. Sistem girdi olarak test görüntüsü almakta ve görüntünün ait olduğu sınıfı tahmin etmektedir.

2.2 Metrik Öğrenme

Problemi sınıflandırma olarak ele alıp derin öğrenme uygulanabildiğini ve sınıflandırma yönteminin bizim problemimizi tam olarak çözmediğini gözlemledikten sonra farklı bir derin öğrenme yöntemi olarak metrik öğrenme kullanılması tercih edilmiştir.

Burada hedeflenen görüntüler arası benzerlikleri kullanarak yeni bir görüntü geldiğinde mevcut görüntüler içerisindeki en benzer görüntü ve bu görüntü ile arasındaki uzaklığın tespit edilmesidir. Aralarında uzaklığın piksel veya km cinsinden tespit edilmesiyle ardışık olarak yeni tahmin edilen noktaya gidilebilecek ve devamında aynı işlemin pek çok defa tekrar edilmesiyle doğru konum bulunabilecektir.

Metrik öğrenme yöntemlerinden farklı problemler üzerinde en çok uygulananlar ikiz ağlar ve üçüz ağlar yöntemleridir. İlk olarak bu yöntemler problem üzerinde uygulanmıştır. İkiz ve üçüz ağlardan başarı elde edilemediği gözlemlenmiş ve problemin çözümü için evrişimsel sinir ağları üzerine kurulu bir model tercih edilmiştir.


Bölüm 2.2.1 de derin öğrenme yöntemlerinden olan ikiz ağlar hakkında bilgi verilmektedir. Bu bilginin yanında problemin çözümünde uygulanan ağ yapısı

anlatılmakta ve ikiz ağılar modelindeki görüntülerin etiketlenmesi örnek görüntüler üzerinde gösterilmektedir. Bölüm 2.2.2 de İkiz ağılar yönteminin haricinde model tarafındaki benzerlik metriğinin öğrenilmesi işlemini görüntülerin bir ön işlemden geçirilerek tek bir görüntü haline getirilmesi, bu görüntünün yön bilgisi olduğu ve olmadığı durumlarda nasıl etiketleme yapıldığı anlatılmakta ve önerilen yöntemde kullanılan model parametreleri verilmektedir.

2.2.1 İkiz Ağılar ile Metrik Öğrenme

İkiz ağılar karşılaştırılabilir iki şey arasında benzerlik veya ilişki probleminin çözümünde yayın olarak kullanılmaktadır. Uygulama alanlarına; iki farklı cümlelerin girdiği bir model ve çıktı olarak ne kadar benzer olup olmadıklarına dair bir skor [24] veya imza doğrulama [23] problemi örnek olarak verilebilir.

İkiz ağılar içerisinde iki adet aynı yapıda sinir ağıları modeli bulunduran alt ağlardır. Aynı yapıda denilmesinin sebebi içerdiği parametreler ve ağırlıklar aynıdır. Genel olarak iki girdi alınan ve iki aynı alt ağdan oluşan ve bu alt ağların girdilerinin çıktılarını tek bir yere aktaran ve oradan sonuç üreten ağlardır.




Şekil 2.3: İkiz ağılar ile metrik öğrenmede görüntülerin etiketlenmesi.

İkiz ağlar modeli girdi olarak iki görüntü almaktadır. Bu görüntüler birbiriyle aynı veya farklı olabilir. Görüntülerin aynı veya farklı olmalarına göre etiketleme işlemleri Şekil 2.3’de gösterilmektedir. Girdi olarak alınan iki görüntü birbiriyle aynı veya benzer ise etiket değeri 1, farklı ise etiket değeri 0 olarak atanmaktadır.

Tablo 2.2: İkiz ağlar model.


Input 64×64 Gray-Scale image	Input 64×64 Gray-Scale image
128 FC ReLU	128 FC ReLU
Dropout 0.1	Dropout 0.1
128 FC ReLU	128 FC ReLU
Dropout 0.1	Dropout 0.1
128 FC ReLU	128 FC ReLU
Lambda Fonksiyonu, Öklid uzaklığı	

Tablo 2.2’deki ikiz ağlar modeli iki farklı ağ modelinin sonuçlarının birleşimi şeklinde oluşan bir modeldir. Sol ve sağ tarafta yer alan iki model birebir aynıdır. Yalnızca bu modeller arasında ağırlık paylaşımı söz konusudur. Modeller içerisinde kullanılan dropout işlemi ezberleme olmaması için tercih edilmiştir. Model içerisinde evrişim katmanları kullanılmamıştır. Yalnızca tam bağlı katmanları yani doğrusal katmanları içermektedir. Bunun sebebi görüntülerin doğrusal uzay içerisinde ayrışabileceğinin ön görülmesidir. Ağ yapısı içerisinde evrişim katmanlarının kullanıldığı modeller de mevcuttur.




Şekil 2.4: Radar görüntülerinin girdi olarak alındığı ikiz ağlar modelinin eğitim aşaması.

Şekil 2.4’de ikiz ağlar yöntemiyle konum tahmini işlemine ait eğitim modeli yer almaktadır. Burada sadece radar görüntülerinin olduğu durumların anlaşılabilmesi için her iki farklı modelin girdisi olarak radar veri kümesi gösterilmiştir. Bu modeller arasındaki ağırlık paylaşımı şekil üzerinde görülmektedir. Model içerisinde doğrusal olmayan evrişim katmanı kullanılmamış ve verilerin doğrusal uzayda ayrışabileceği öngörülmüştür.




Şekil 2.5: Radar ve uydu görüntülerinin girdi olarak alındığı ikiz ağlar modelinin eğitim aşaması.

Şekil 2.5’de ikiz ağlar yöntemiyle konum tahmini işlemine ait eğitim modeli yer almaktadır. Burada radar ve uydu görüntülerinin sistemin iki ayrı koluna girdi olarak verildiği görülmektedir. Görüntüde yer alan her iki ayrı kol içerikleri aynı olarak bir modele işaret etmektedir. Bu modeller arasındaki ağırlık paylaşımı şekil üzerinde görülmektedir.



Şekil 2.6: Radar görüntülerinin girdi olarak alındığı ikiz ağlar modelinin test aşaması.

Şekil 2.6’de ikiz ağlar yöntemiyle konum tahmini işlemine ait test aşaması yer almaktadır. Yalnızca radar görüntülerinin kullanıldığı durumları göstermektedir. İkiz ağlar modeline girdi olarak test görüntüsü ve referans görüntü verilmektedir. Bu görüntüler sonucunda sistem sonuç olarak 0 ile 1 arasında bir değer dönmektedir. Burada çıkan sonuç 0’a ne kadar yakın ise o kadar ayırık görüntüler olduğu, 1’e ne kadar yakın ise o kadar benzer görüntüler olduğu anlamına gelmektedir.




Şekil 2.7: Radar ve uydu görüntülerinin girdi olarak alındığı ikiz ağlar modelinin test aşaması.

Şekil 2.7’de ikiz ağlar yöntemiyle konum tahmini işlemine ait test aşaması yer almaktadır. Radar ve uydu görüntülerinin kullanıldığı durumları göstermektedir. İkiz ağlar modeline girdi olarak radar test görüntüsü ve uydu referans görüntü verilmektedir. Bu görüntüler sonucunda sistem sonuç olarak 0 ile 1 arasında bir değer dönmektedir. Burada çıkan sonuç 0’a ne kadar yakın ise o kadar ayırık görüntüler olduğu, 1’e ne kadar yakın ise o kadar benzer görüntüler olduğu anlamına gelmektedir.

Tablo 2.3: İkiz ağlar evrişimsel model.


Input 128×128 Gray-Scale image	Input 128×128 Gray-Scale image
3×3 conv. 64 ReLU	3×3 conv. 64 ReLU
3×3 max-pooling	3×3 max-pooling
3×3 conv. 128 ReLU	3×3 conv. 128 ReLU
2×2 max-pooling	2×2 max-pooling
Dropout 0.1	Dropout 0.1
256 FC ReLU	256 FC ReLU
Dropout 0.1	Dropout 0.1
512 FC Softmax	512 FC Softmax
Lambda Fonksiyonu, Öklid uzaklığı	

Tablo 2.3'deki ikiz ağlar modeli iki farklı ağ modelinin sonuçlarının birleşimi şeklinde oluşan bir modeldir. Sol ve sağ tarafta yer alan iki model birebir aynıdır. Yalnızca bu modeller arasında ağırlık paylaşımı söz konusudur. Modeller içerisinde kullanılan dropout işlemi ezberleme olmaması için tercih edilmiştir. Burada yer alan modelin Tablo 2.2'deki modelden farkı içerisinde kullanılan doğrusal olmayan evrişim (konvolüsyon) katmanıdır.




Şekil 2.8: Radar görüntülerinin girdi olarak alındığı ve içerisinde evrimsel katmanlar içeren ikiz ağlar modelinin kullanıldığı eğitim aşaması.

Şekil 2.8’de ikiz ağlar yöntemiyle konum tahmini işlemine ait test aşaması yer almaktadır. Şekil 2.4’de yer alan modelden farkı içerisinde kullanılan doğrusal olmayan evrişim(konvolüsyon) katmanıdır. Yalnızca radar görüntülerinin kullanıldığı durumları göstermektedir. İkiz ağlar modeline girdi olarak radar test görüntüsü ve radar referans görüntü verilmektedir. Bu görüntüler sonucunda sistem sonuç olarak 0 ile 1 arasında bir değer dönmektedir. Burada çıkan sonuç 0’a ne kadar yakın ise o kadar ayırık görüntüler olduğu, 1’e ne kadar yakın ise o kadar benzer görüntüler olduğu anlamına gelmektedir.




Şekil 2.9: Radar ve uydu görüntülerinin girdi olarak alındığı ve içerisinde evrişimsel katmanlar içeren ikiz ağlar modelinin kullanıldığı eğitim aşaması.

Şekil 2.9’de ikiz ağlar yöntemiyle konum tahmini işlemine ait test aşaması yer almaktadır. Şekil 2.5’de yer alan modelden farkı içerisinde kullanılan doğrusal olmayan evrişim(konvolüsyon) katmanıdır. Radar ve uydu görüntülerinin kullanıldığı durumları göstermektedir. İkiz ağlar modeline girdi olarak radar test görüntüsü ve radar referans görüntü verilmektedir. Bu görüntüler sonucunda sistem sonuç olarak 0 ile 1 arasında bir değer dönmektedir. Burada çıkan sonuç 0’a ne kadar yakın ise o kadar ayırık görüntüler olduğu, 1’e ne kadar yakın ise o kadar benzer görüntüler olduğu anlamına gelmektedir.



Şekil 2.10: Radar görüntülerinin girdi olarak alındığı ve içerisinde evrimsel katmanlar içeren ikiz ağlar modelinin kullanıldığı test aşaması.

Şekil 2.10’de ikiz ağlar yöntemiyle konum tahmini işlemine ait test aşaması yer almaktadır. Şekil 2.6’de yer alan modelden farkı içerisinde bulunan doğrusal olmayan evrişim (konvolüsyon) katmanıdır. Yalnızca radar görüntülerinin kullanıldığı durumları göstermektedir. İkiz ağlar modeline girdi olarak test görüntüsü ve referans görüntü verilmektedir. Bu görüntüler sonucunda sistem sonuç olarak 0 ile 1 arasında bir değer dönmektedir. Burada çıkan sonuç 0’a ne kadar yakın ise o kadar ayırık görüntüler olduğu, 1’e ne kadar yakın ise o kadar benzer görüntüler olduğu anlamına gelmektedir.



Şekil 2.11: Radar ve uydu görüntülerinin girdi olarak alındığı ve içerisinde evrimsel katmanlar içeren ikiz ağlar modelinin kullanıldığı test aşaması.

Şekil 2.11’de ikiz ağlar yöntemiyle konum tahmini işlemine ait test aşaması yer almaktadır. Şekil 2.7’de yer alan modelden farkı içerisinde bulunan doğrusal olmayan evrişim (konvolüsyon) katmanıdır. Radar ve uydu görüntülerinin kullanıldığı durumları göstermektedir. İkiz ağlar modeline girdi olarak test görüntüsü ve referans görüntü verilmektedir. Bu görüntüler sonucunda sistem sonuç olarak 0 ile 1 arasında bir değer dönmektedir. Burada çıkan sonuç 0’a ne kadar yakın ise o kadar ayırık görüntüler olduğu, 1’e ne kadar yakın ise o kadar benzer görüntüler olduğu anlamına gelmektedir.

2.2.2 Evrimsel (Konvolüsyonel) Sinir Ağları ile Metrik Öğrenme

Deniz araçlarının konum tespiti probleminin çözümünde İkiz ağlar yöntemi başarılı sonuçlar üretememiştir. Bu yöntemlerin başarısız olmasından sonra çözüm için evrimsel sinir ağlarından oluşan bir model ve onun kullanımı için bir yöntem

uygulanmıştır. Burada hedeflenen görüntüler arasındaki benzerliğin öğrenilmesidir. Problem sınıflandırma problemi olarak ele alınmıştır. Buradaki sınıflar 0 ile 15 arasındaki sayılardan oluşmaktadır. İki görüntü arasındaki piksel uzaklığını göstermektedir. Bu yöntem içerisinde radar görüntüleri doğrudan kullanılabildiği gibi uydu görüntüleriyle birlikte de kullanılabilmektedir. İki alt bölüm halinde inceleyecek olursak birinci bölüm yalnızca radar görüntülerinin kullanılarak tahmin / tespit edilmesi, ikinci bölüm ise uydu görüntüleriyle birlikte kullanılarak tahmin / tespit edilmesidir.

Bölüm 2.2.2.1’ de yalnızca radar görüntülerinin girdi olarak alındığı sisteme ait bilgiler bulunmaktadır. Bölüm 2.2.2.2’de ise radar ve uydu görüntülerinin birlikte kullanıldığı sistem anlatılmıştır.

2.2.2.1 Radar görüntülerinin kullanılarak tahmin/tespit edilmesi


Bu bölümde yalnızca radar görüntüleri kullanılarak deniz araçlarının konumlarının tespiti için çalışmalar yapılmıştır. Önerilen model yapısı Tablo 2.4’deki gibidir.

Tablo 2.4: Sınıflandırma için kullanılan ağ modeli.

Input 128×128 Gray-Scale image
3×3 conv. 32 ReLU
3×3 conv. 64 ReLU
2×2 max-pooling
Dropout 0.25
128 FC ReLU
Dropout 0.5
15 Softmax

Tablo 2.4’te yer alan model girdi olarak 128×128 boyutunda görüntü almaktadır. Bu görüntü aslında iki farklı 64×64 ’lük görüntünün ön işleminden geçirilerek oluşturulduğu bir görüntüdür. Bu görüntüler Şekil 2.12’de gösterildiği şekliyle ön işleminden geçirilmektedir. Bu görüntüler üzerinde 32 tane 3×3 ’lük filtre gezdirilmiş ve bu filtrelere özgü özelliklerin haritası çıkarılmıştır. Devamında 64 tane 3×3 ’lük filtre

gezdirilmiş ve özellik haritası güncellenmiştir. Model içerisinde kullanılan dropout 0.25 ve dropout 0.5 katmanları ezberlemenin önüne geçilmesi için yapılmaktadır.



Şekil 2.12: Radar görüntüleri arasındaki ilişkinin öğrenilmesi için ön işlemden geçirilmesi.

Şekil 2.12’da 64x64’lük iki farklı görüntünün aralarındaki ilişkinin öğrenilmesi için nasıl bir ön işlemden geçirildiği gösterilmektedir. Radar görüntüleri konum tahmin modeline doğrudan girdi olarak verilmemektedir. Onun yerine birbirleriyle farkları ve çarpımları alınarak ve tek bir görüntü haline getirilerek verilmektedir. Görüntüler arasındaki benzerlik ilişkisi bu şekilde sağlanmaktadır.


Girdi olarak alınan her iki görüntünün de sınıfları görüntülerin gerçek dünyadaki enlem ve boylam değerleridir. Fakat Tablo 2.4’te yer alan modelin çıktısı 0 ile 15 arasındaki bir rakamdır. Bu rakamlar görüntülerin gerçek dünya uzaklıkları ile ilişkilidir.

Ön işlemden geçirilen görüntü Tablo 2.5 yer alan gerçek dünya uzaklıklarına karşılık gelen etiket değeri ile etiketlenir.

Sınıf değerlerinin belirlenmesinden sonra eldeki radar görüntülerini Şekil 2.12’deki gibi birbirleriyle ikili yaparak eğitim işlemi gerçekleştirilir.


Tablo 2.5: 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 – 200	9
200 – 300	10
300 – 500	11
500 – 750	12
750 – 1000	13
1000 – ∞	14



Şekil 2.13: Radar görüntüleri metrik öğrenme eğitim aşaması.

Şekil 2.13’de metrik öğrenme modelinin kullanılarak konum tahmini işlemine ait eğitim aşaması yer almaktadır. Yalnızca radar görüntülerinin kullanıldığı durumu içermektedir. Ham radar görüntüleri 64x64 boyutundadır. Bu görüntüler Şekil 2.12’de gösterildiği şekliyle ön işlemden geçirilerek 128x128 boyutunda görüntülere dönüştürülmektedir. Metrik öğrenme modeli içerisinde iki tane evrişim iki tane tam bağlı katman bulunmaktadır. Modelin çıktısı 0 ile 15 arasındadır. Bu çıktı değeri girdi olarak verilen test ve referans görüntü arasındaki gerçek dünya uzaklıklarının piksele karşılık gelen değeridir.




Şekil 2.14: Radar görüntüleri metrik öğrenme test aşaması.

Şekil 2.14’da metrik öğrenme modelinin kullanılarak konum tahmini işlemine ait test aşaması yer almaktadır. Yalnızca radar görüntülerinin kullanıldığı durumu içermektedir. Ham radar görüntüleri 64x64 boyutundadır. Test görüntüsü radar veri kümesi içerisinde her alan bütün görüntüler ile ayrı ayrı olarak ön işlemden geçirilerek modele girdi olarak verilmeye hazırlanmıştır. Model çıktısı olan her bir görüntü için 15 boyutlu 0 ile 1 arasında bir değer döndürmektedir. Dönen değerin 0 a yakın olması görüntülerin az benzediği veya hiç benzemediği, 1 e yakın olması ise görüntülerin çok benzediği veya benzer olduğu anlamına gelmektedir. 15 boyutlu dizi içerisindeki en büyük sayının ait olduğu yer sınıf değeridir.


2.2.2.2 Radar ve Uydu görüntülerinin kullanılarak tahmin/tespit edilmesi

Bölüm 2.2.2.1'deki önerilen sistem yalnızca radar görüntülerinin olduğu durumlar için geçerlidir. Bu bölümde sistemin başarısının artırılması amacıyla radar görüntülerinin yanında radar görüntülerinin gerçek dünya konumlarına ait uydu görüntülerinin alınarak eklendiği radar ve uydu görüntülerinin birlikte kullanıldığı bir sistem anlatılmaktadır. Bu sebeple Şekil 2.12'deki gibi bir görüntü ikilisi oluşturmak yerine bu görüntülerle aynı yere ait uydu görüntülerinin de eklenerek Şekil 2.15'deki gibi bir görüntü oluşturulmaktadır.




Şekil 2.15: Radar ve uydu görüntülerinin aralarındaki ilişkinin öğrenilmesi için önışlemden geçirilmesi.

Yalnızca radar görüntüleri kullanıldığı durumda (Şekil 2.12) iki farklı radar görüntüsü farkları ve çarpımları alınarak 2x2'lik bir görüntü olarak oluşturuluyordu. Burada ise radar görüntülerine ek olarak kullanılan uydu görüntüleri ile birlikte bu 2x2'lik görüntü yerine 3x3'lük bir görüntü oluşturulup sisteme girdi olarak hazır hale geliyor.



Şekil 2.16: Radar ve uydu görüntüleri kullanarak metrik öğrenme yapılması (Eğitim aşaması).

Şekil 2.16’de metrik öğrenme modelinin kullanılarak konum tahmini işlemine ait eğitim aşaması yer almaktadır. Radar ve uydu görüntülerinin birlikte kullanıldığı durumu içermektedir. Ham radar ve uydu görüntüleri 64x64 boyutundadır. Bu görüntüler Şekil 2.15’de gösterildiği şekliyle ön işleminden geçirilerek 192x192 boyutunda görüntülere dönüştürülmektedir. Metrik öğrenme modeli içerisinde iki tane evrişim iki tane tam bağlı katman bulunmaktadır. Modelin çıktısı 0 ile 15 arasındadır. Bu çıktı değeri girdi olarak verilen test ve referans görüntü arasındaki gerçek dünya uzaklıklarının piksele karşılık gelen değeridir.



Şekil 2.17: Radar ve uydu görüntüleri kullanılarak metrik öğrenme yapılması (Test aşaması).

Şekil 2.17’de metrik öğrenme modelinin kullanılarak konum tahmini işlemine ait test aşaması yer almaktadır. Yalnızca radar görüntülerinin kullanıldığı durumu içermektedir. Ham radar görüntüleri 64x64 boyutundadır. Test görüntüsü radar veri kümesi içerisinde her alan bütün görüntüler ile ayrı ayrı olarak ön işleminden geçirilerek modele girdi olarak verilmeye hazırlanmıştır. Model çıktısı olan her bir görüntü için 15 boyutlu 0 ile 1 arasında bir değer döndürmektedir. Dönen değerin 0 a yakın olması görüntülerin az benzediği veya hiç benzemediği, 1 e yakın olması ise görüntülerin çok benzediği veya benzer olduğu anlamına gelmektedir. 15 boyutlu dizi içerisindeki en büyük sayının ait olduğu yer sınıf değeridir.

3. VERİ KÜMESİ

Bu bölümde tez kapsamında kullanılan radar ve uydu görüntülerinin temin edilme şekilleri ve temin edildiği kaynaklar anlatılmaktadır.

Bölüm 3.1 de radar görüntülerinin hangi kaynaktan alındığı ve nasıl alındığı anlatılmaktadır. Bunun yanında alınan görüntülerin boyut, çözünürlük gibi detay.


Bölüm 3.2 de uydu görüntülerin hangi kaynaktan alındığı ve nasıl alındığı bilgilerinin yanında alınan görüntülerin boyut, çözünürlük gibi detay bilgileri anlatılmaktadır.

Bölüm 3.3 de ise 3.1 de anlatılan veri toplama yöntemi sonucunda kaydedilen video üzerinden ham görüntülerin nasıl alındığı ve bu görüntüler içerisinde görüntülere ait enlem-boylam bilgilerinin nasıl çıkarıldığı, hangi kütüphane yardımıyla bu işlemin gerçekleştirildiği anlatılmaktadır.

3.1 Veri Toplama (Radar Görüntüleri)

Radar görüntüleri SPx Cambridge Pixel Radar Simulator uygulamasından sağlanmıştır. Bu çalışmada gerçek radar görüntüsü temin edilememiştir. Simülasyon uygulamasının lisans ücreti çok yüksek olduğundan dolayı 1 aylık ücretsiz sürümü kullanılarak görüntüler alınmıştır. Simülasyon uygulamasından görüntü alabilmek için ilk olarak deniz aracının izleyeceği rota seçilmelidir. Rota olarak Marmara kıyıları seçilmiştir. Deniz aracı hareket ederken “Ekran Görüntüsü Kaydetme” programı yardımıyla ekrandaki hareketler video olarak kaydedilmiştir.


Kaydedilen her bir radar görüntü renkli görüntüdür yani üç kanaldan oluşmaktadır (KYM renk uzayı). Her bir radar görüntüsü 256 x 256 piksel çözünürlüğünde ve 11-12 KB boyutundadır. Toplamda 40.075 tane görüntü kaydedilmiştir. Bu görüntülerin kapladığı alan yaklaşık 500 MB. Kaydedilen video görüntüsü içerisinde alınan rastgele bir ham görüntü Şekil 7’deki gibidir. Veri kümesinin oluşturulması için video içerisinde bazı bilgilerinin çıkarılması gerekmektedir.



Şekil 3.1: Simülasyondan alınan ham radar görüntüleri

Kaydedilen video görüntüsü “OpenCV” kütüphanesi yardımıyla kare kare okunabilmektedir. Veri kümesinin oluşturulmasında her bir sınıfta 10 ile 12 arasında görüntü olacaktır kabulü yapılmıştır ve video içerisinde görüntüler okunurken 10’ar kare atlanarak okunmuştur. Bu kabulün ardından okunan her bir görüntü üzerinde


OCR Kütüphanesi ile Şekil 3.2’de yer alan görüntünün sol alt köşesinde yer alan enlem/boylam değerlerinin okunması gerekmektedir. Veri kümesinde ki sınıf isimleri enlem ve boylam değerleridir.



Şekil 3.2: Simülasyondan alınan ham radar görüntüsü, sol alt köşede konum bilgileri yer almakta.

3.2 Veri Toplama (Uydu Görüntüleri)

Uydu görüntüleri Google haritalar servisinden alınmıştır. Her bir radar görüntüsüne karşılık gelecek şekilde aynı enlem ve boylam değerlerinde olan uydu görüntüleri alınmıştır. Kaydedilen her bir uydu görüntüsü renkli görüntüdür yani üç kanaldan oluşmaktadır (KYM renk uzayı). Her bir uydu görüntüsü 256 x 256 piksel çözünürlüğünde ve 11-12 KB boyutundadır. Toplamda 40.075 tane uydu görüntü kaydedilmiştir. Bu görüntülerin kapladığı alan yaklaşık 500 MB boyutundadır. Kaydedilen örnek uydu görüntüleri Şekil 3.3’deki gibidir. Uydu görüntüleri radar görüntüleriyle aynı şekilde bölünmekte ve sınıflar oluşturulmaktadır. Görüntüler ortalama her bir sınıfta 10-12 görüntü olacak şekilde bölünmektedir. Bölünde işlemi yapılırken birbirine en yakın 10-12 görüntü alınarak bu görüntülerin ortalama enlem boylam değerleri sınıf değeri olarak isimlendirilir.



Şekil 3.3: Google haritalar servisinden indirilen örnek uydu görüntüsü.

4. DENEYLER

4.1 de sınıflandırma probleminin çözümü için önerilen derin öğrenme modeli kullanılarak yapılan deneylerde elde edilen bulgular, deney sonuçları ve bu deneyler esnasında yapılan kazanımlar anlatılmaktadır. 4.2 de metrik öğrenme için kullanılan ikiz ağlar modelinin kullanıldığı deneyler hakkında bilgiler içermektedir. Burada girdi görüntülerinin hazırlanması, örnek test senaryosu, deneylerde elde edilen başarımlar ve bu başarımların gösterildiği grafikler ile tablolar yer almaktadır. 4.3 tez kapsamında hedeflenen çalışmanın sonucuna ulaşıldığı bölümdür. Burada diğer iki bölüme kıyasla daha uzun durulmuştur. Bu bölüm altında konum tahmininin yön bilgisi olmaksızın doğrudan uzaklığı tahmin ederek yapılan testler, test senaryoları, örnek test görüntüleri, bunların tablo ve grafikleri yer almaktadır.

4.1 Evrişimsel (Konvolüsyonel) Sinir Ağları Kullanılarak Sınıflandırma

Bu bölümde evrişimsel sinir ağları kullanılarak sınıflandırma yapmak ile ilgili deneyler anlatılmaktadır. Kullanılan radar veri kümesinin oluşturulması Bölüm 3.1’de anlatılmaktadır. Oluşturulan veri kümesi 3346 sınıftan ve 40.075 adet görüntüden oluşmaktadır. Deneyler genel olarak aktivasyon fonksiyonlarının değiştirilmesi, epok sayısının değiştirilmesi, optimizasyon fonksiyonunun değiştirilmesi ve evrişim katmanında kullanılan filtre boyu ile filtre sayısının değiştirilmesiyle gerçekleştirilmiş ve karşılaştırılmıştır.

Tablo 4.1: Öğrenme katsayısının değiştirilerek test edilmesi.

Optimizasyon Tipi	Öğrenme Kat Sayısı	K-katlamalı	Top	Doğruluk
SGD	0.01	10	5	58.28
SGD	0.03	10	5	80.44
SGD	0.05	10	5	81.41
SGD	0.07	10	5	80.12
SGD	0.09	01	5	66.2

İlk olarak öğrenme katsayılarının değiştirilerek testler yapılmıştır. Bu testlere ait sonuçlar Tablo 4.1'deki gibidir. Yapılan bu deneyde varsayılan optimizasyon fonksiyonu olarak SGD kullanılmıştır. Devam eden testlerde optimizasyon fonksiyonu da değiştirilerek deneyler gerçekleştirilecektir. En yüksek başarımlı öğrenme katsayı değeri 0.05 olduğunda elde edilmiş ve 81.41 bulunmuştur. Farklı bir optimizasyon fonksiyonu kullanılarak yapılan testlere ait sonuçlar Tablo 4.2'deki gibidir.

Tablo 4.2: Optimizasyon fonksiyonunun değiştirilerek test edilmesi.

Optimizasyon Tipi	Öğrenme Katsayısı	K-Fold	Top (1 veya 5)	Doğruluk
ADAM	0.001	10	5	8.49
ADAM	0.002	10	5	0
ADAM	0.003	10	5	0

Tablo 4.2 incelendiğinde ADAM fonksiyonu kullanıldığında ve öğrenme katsayısı 0.002 ve 0.003 kullanıldığında doğruluk değeri sıfır çıkmıştır. Bu fonksiyonun kullanımı için uygun olmadığı gözlemlenmiştir. Optimizasyon tipi sabit tutularak aktivasyon tipinin değiştirilerek yapılan testlere ait sonuçlar Tablo 4.3'deki gibidir.

Tablo 4.3: Aktivasyon fonksiyonunu değiştirilerek gerçekleştirilmesi.

Optimizasyon Tipi	Aktivasyon Tipi	Öğrenme Katsayısı	K-Fold	Top	Doğruluk
SGD	Sigmoid	0.05	10	5	62.54
SGD	Softmax	0.05	10	5	81.41

Tablo 4.3 incelendiğinde aktivasyon fonksiyonu olarak “softmax” kullanıldığında doğruluk oranının daha yüksek olduğu gözlemlenmiştir. Burada “softmax” kullanıldığında fazla çıkmasının sebebi “softmax” fonksiyonunun sınıflandırma problemine uygun olmasından kaynaklıdır. Öyle ki sınıflandırma probleminde derin öğrenme modeli çıktı olarak mevcut sınıflar içerisinde bir tanesini ve tahmin değeri en yüksek olanı verecektir. Bunun içinde “softmax” yapmak gerekecektir.

Bu bölümde gerçekleştirilen deneyler deniz araçlarının konumlarının tahmini probleminin çözümünde doğrudan rol oynamamaktadır. Hazırlanan radar veri kümesi üzerinde derin öğrenme yöntemlerinin uygulanabilirliğinin kontrol edilmesi için gerçekleştirilen bir çalışmadır.

4.2 İkiz Ağlar Kullanılarak Metrik Öğrenme

Bu bölümde evrimsel ikiz ağlar kullanılarak deniz araçlarının konumu tahmini yapmak ile ilgili deneyler anlatılmaktadır. Kullanılan radar veri kümesinin oluşturulması Bölüm 3.1’de anlatılmaktadır. İkiz ağlar iki farklı girdi verisini aynı model üzerinden geçirerek sonucunda bu iki girdinin birbiriyle benzer (aynı) veya farklı olduğunu tahmin eder. Bu iki model arasında ağırlık paylaşımı yapılabileceği gibi; eğer iki görüntü birbirinin benzeri ise (örneğin; farklı rotasyonlardaki aynı kişinin yüz görüntüleri), ağırlık paylaşımı olmadan da işlemi gerçekleştirebilmektedir. İkiz ağlar modeline girdi olarak verilen görüntülerin nasıl etiketlendiği Bölüm 2.2.1’de anlatılmaktadır. İkiz ağlarda yer alan her bir ağ için evrişim katmanı olmadan ve evrişim katmanı ile birlikte deneyler yapılmıştır. Ağ yapısı içerisinde evrişim katmanı olmayan durumda üç adet tam bağlı katman bulunmaktadır. Evrişim katmanı kullanıldığında ise üç adet evrişim katmanı ve devamında üç adet tam bağlı katman tercih edilmiştir. Ağ yapısı içerisinde evrişim katmanı filtre sayısı, çekirdek boyutu, öğrenme katsayısı, optimizasyon fonksiyonu gibi parametreler değiştirilerek sonuç üzerindeki etkileri gözlemlenmiştir.

Yalnızca tam bağlı katman kullanılan deneylerde eğitim için kullanılan görüntüsü sayısı 80. 000, test etmek için kullanılan görüntüsü sayısı 27. 000’dir. Elde edilen sonuçlar Tablo 4.4’deki gibidir.

Tablo 4.4: Yalnızca tam bağlı katmanlardan oluşan ikiz ağlar modelinin deney sonuçları.

Filtre Sayıları	Eğitim Doğruluk Değeri	Test Doğruluk Değeri
128, 128, 128	% 95.12	%93.1
128, 256, 512	% 94.12	%93.1
512, 1024, 2048	%95.84	%94.01
512, 1024, 4096	%96.04	%94.16

Tablo 4.4’da yer alan sonuçlar incelendiğinde filtre sayıları arttıkça eğitim ve test doğruluk değerlerinin arttığı görülmektedir. Fakat filtre sayılarının artması sistemin eğitim ve test sürelerini uzatmaktadır. Tam bağlı katmanlardan önce evrişim katmanları kullanıldığında ise ortaya çıkan sonuçlar Tablo 4.5’deki gibidir. Eğitim ve test aşamalarında kullanılan görüntü sayısı bir önceki deneylerde kullanılan sayı ile aynıdır.

Tablo 4.5: Evrişim katmanları ile birlikte tam bağlı katmanlardan oluşan ikiz ağlar modelinin deney sonuçları.

Filtre Sayıları	Eğitim Doğruluk Değeri	Test Doğruluk Değeri
128, 128, 128	%95.12	%93.10
128, 256, 512	%94.11	%93.10
512, 1024, 2048	%95.85	%94.04
512, 1024, 4096	%96.05	%94.02

Hata hesaplaması görüntüler arasındaki gerçek dünya uzaklıklarını karşılaştırılarak yapılmaktadır. Veri kümesinde yer alan görüntü sınıfları o enlem ve boylam değerlerini içermektedir. Girdi olarak verilen görüntülerin enlem ve boylam değerlerine matematiksel işlem uygulayarak aralarındaki gerçek dünya mesafesi bulunmaktadır. Bu mesafe ile modelin tahmin ettiği sonuç karşılaştırılarak hata hesaplaması yapılmaktadır.

Model içerisine evrişim katmanlarının eklenmesi ek bir maliyet oluşturmakta ve başarımlar olarak pek fayda sağlamadığı gözlemlenmektedir. Bu sebeptendir ki Tam bağlı katmanların kullanılması gerek performans gerekse başarımlar açısından tatmin edicidir.

Yapılan deneyler sonucunda görülmüştür ki; az sayıda görüntü olmasına rağmen yapılan eğitimler sonunda %95 oranında başarılı olarak uydu ve radar görüntülerinin benzer veya farklı olduğunu tahmin edebilmektedir. Fakat burada yapılanlar iki görüntünün birbirlerine göre konumları veya gerçek dünya konumları hakkında pek fazla bilgi vermemektedir. Bu sebeple ikiz ağlar yöntemiyle görüntüler arasında benzerlik metriğinin öğrenilmesi kısmı problemin çözümü için tercih edilememektedir. İkiz ağlar modelinde eğitim aşamasında görüntüleri etiketlerken 0 yani farklı veya 1 yani aynı olarak etiketliyoruz. Bu etiketleme işlemini 0 veya 1’den farklı bir rakam olarak kullanamadık. O sebeple bu yöntem problemin çözümünde kullanılamayacaktır.

4.3 Evrişimsel (Konvolüsyonel) Sinir Ağları Kullanılarak Metrik Öğrenme

Deniz araçlarının konumlarının tahmin edilmesi probleminde ikiz ve üçüz ağlar beklenen başarıyı gösteremedi. Bu sebeple görüntüler arasındaki benzerlik metriğini öğrenmeyi hedefleyen ve 4.3.1 ile 4.3.2 de belirtildiği gibi birden fazla görüntünün tek görüntü olarak birleştirilmesi ve bu şekilde sistemin eğitilmesi yapılmıştır.

Bu yapılan çalışma iki bölümden oluşmaktadır. Birinci bölümde yön bilgisi olmadan herhangi bir görüntüye ait en yakın koordinat bilgisi ve ne kadar uzak olduğu piksel cinsinden verilmektedir. İkinci bölümde ise en yakın koordinat bilgisi yanında koordinat düzleminde x ve y yönlerinde kaçar piksel uzak olduğu verilmektedir. İkinci çalışma birincide yapılan çalışma da elde edilen veriler ile üzerine eklenerek gerçekleştirilmiştir.

4.3.1 Yön bilgisi olmaksızın konum tahmini


Görüntüler arasındaki benzerliğin öğrenilmesi için 4.3.1 ve 4.3.2 de anlatıldığı gibi görüntülerin yan yana ve alt alta birleştirilmesiyle oluşturulan tek görüntüler ile eğitilmiş ve testlerde bu şekilde gerçekleştirilmiştir. Görüntülerin yan yana ve alt alta eklenmesi haricinde farklı renk kanalları şeklinde arka arkaya ekleyerek de denemeler gerçekleştirilmiş fakat yan yana ve alt alta eklendiği haliyle daha yüksek doğruluk sonucu elde ettiği gözlemlenmiş bu sebeple bu yöntem ile devam edilmiştir. Bu çalışma esnasında yön bilgisi göz ardı edilmiş sadece görüntüler arasındaki genel uzaklık piksel cinsinden kabul edilmiştir.

Yapılan deneylerde iki farklı veri kümesi kullanılmıştır. Kullanılan veri kümelerinin nasıl oluşturulduğu daha önceki bölümlerde anlatılmıştır. Bu kümlerden ilki 504 sınıftan yaklaşık 7.000 görüntüden, ikinci küme ise 3346 sınıf yaklaşık 40.000 görüntüden oluşmaktadır. Bu kümeler tablolarda 1 ve 2 olarak isimlendirilmektedir. Deneylerde model parametreleri sabit tutularak yalnızca epok sayısının artırılıp azaltılmasıyla testler gerçekleştirilmiştir. Büyük veri kümesinin kullanıldığı deneylerde eğitim aşaması uzun sürdüğünden dolayı epok değerleri çok büyük sayılar seçilememiştir. Sisteme girdi olarak verilen görüntüler farklı iki görüntünün veya uydu görüntülerini de işe dâhil edecek olursa 4 görüntünün kombinasyonundan


oluştduğundan dolayı deneylerde farklı sayıda ikililer oluşturularak az sayı ile çok sayı arasındaki başarımda gözlenmektedir.

Yapılan deneyler iki farklı şekilde gerçekleştirilmiştir. Birinci olarak doğrudan radar görüntülerinin kendileriyle ilişkisine bakarak tahminin gerçekleştirilmesi, ikinci olarak ise radar ve uydu görüntülerinin kullanılarak gerçekleştirildiği deneylerdir. 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.

Deneyler sonucunda sistem tarafından tespit edilen doğru ve yanlış örnekler, görüntüler arasındaki gerçek uzaklık ve piksel karşılığı ile birlikte Şekil 4.1 ve Şekil 4.2'deki gibidir.



Şekil 4.1: Doğru örnekler.



Şekil 4.2: Hatalı örnekler.

Sadece radar görüntülerinin kullanıldığı deneylere ait sonuçlar Tablo 4.6'daki gibidir. Küçük veri kümesinin kullanıldığı deneylerdeki doğruluk değeri büyük veri kümesinin kullanıldığı deneylerdeki doğruluk değerinden daha yüksektir. Bunun sebebi küçük veri kümesi içerisinde 504 sınıf, büyük veri kümesi içerisinde 3346 sınıf olmasıdır. Sınıf sayısı arttıkça sistemin karmaşıklığı artmakta ve başarımlar düşmektedir.

azalmaktadır. 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 4.6: Radar görüntülerinin deney sonuçları.

Doğruluk Değeri	Ortalama Piksel Hatası	Eğitim Veri Sayısı	Test Veri Sayısı	Epok	Veri Kümesi
0.9678	-	~40K	~9K	30	1
0.9608	-	~40K	~9K	20	1
0.9628	-	~40K	~9K	10	1
0.9545	0.1429	~25K	~25K	10	1
0.9694	0.0896	~25K	~25K	20	1
0.9686	0.0882	~25K	~25K	30	1
0.6973	0.7943	~133K	~30K	10	2
0.7210	0.7089	~160K	~36K	10	2
0.7672	0.6390	~200K	~46K	10	2

Radar ve uydu görüntülerinin birlikte kullanıldığı deneylere ait sonuçlar Tablo 4.7'deki gibidir. Tabloya bakıldığında eğitim veri sayısının artırılmasıyla doğruluk değerinin arttığı gözlemlenmektedir. Bunun sebebi ise çok daha fazla görme olasılığından kaynaklı olarak başarımlar artıyor. Bu sayısının daha fazla artırılması durumunda sistem ezberlemeye doğru gidebilir.


Tablo 4.7: 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

Sistemin eğitimi 200 bin görüntü ile 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.

4.3.2 Yön bilgisi eklenerek konum tahmini

Bir önceki yöntemde yön bilgisi olmadan konum tahmin testlerinden bahsedilmiştir. Verilen bir görüntüden sistemde yer alan yer yakın karşılığı ve bu iki görüntü arasındaki piksel farkı bulunmaktadır. Bulunan piksel farkı üzerinden gerçek dünyada aralarındaki uzaklık yaklaşık olarak Tablo 2’den yardım alınarak öğrenilebilir. Fakat bu uzaklık iki görüntü arasındaki kuş bakışı uzaklığı verecektir. Mevcut görüntü ile sistem tarafından tespit edilen görüntüye ait herhangi bir yön bilgisi olmadığından kafa karışıklığı olacak ve doğru tarafa hareket olmayacaktır. Yön bilgisi olmaksızın yapılan deneylerde elde edilen doğruluk oranı yüksek ve hata payı ile ortalama hata payı düşük olduğundan o yönleme yön bilgisi eklenmek istenmiştir. Bir önceki yöntemde görüntüler 0 ile 15 arasındaki sayılar ile etiketlenmektedir. Burada etiketleme işlemi yön bilgisi eklenmesi için x ve y olarak iki parça ve bu her bir parça kendi içerisinde pozitif ve negatif olacak şekilde iki parçadan oluşan bir ikili sayı dizisi olmuştur.



Şekil 4.3: Yön bilgisi eklenen sistemde görüntü etiketlenmesi.

Görüntülerin etiketleme işleminin nasıl yapıldığı Şekil 4.3’de gösterilmiştir. Burada koordinat düzlemindeki x ve y noktasında yön olarak kabul edilmiştir. Toplamda uzaklıklara göre 15 farklı sınıf olduğundan dolayı ve pozitif negatif olması

durumunda göre bu sayısının $14 + 1 + 14$ şeklinde olacağından tek bir yön için 29 bitlik bir sayı dizisi oluşmaktadır. X ve Y toplamda iki yön olduğundan dolayı bu sayı 58 olmaktadır.

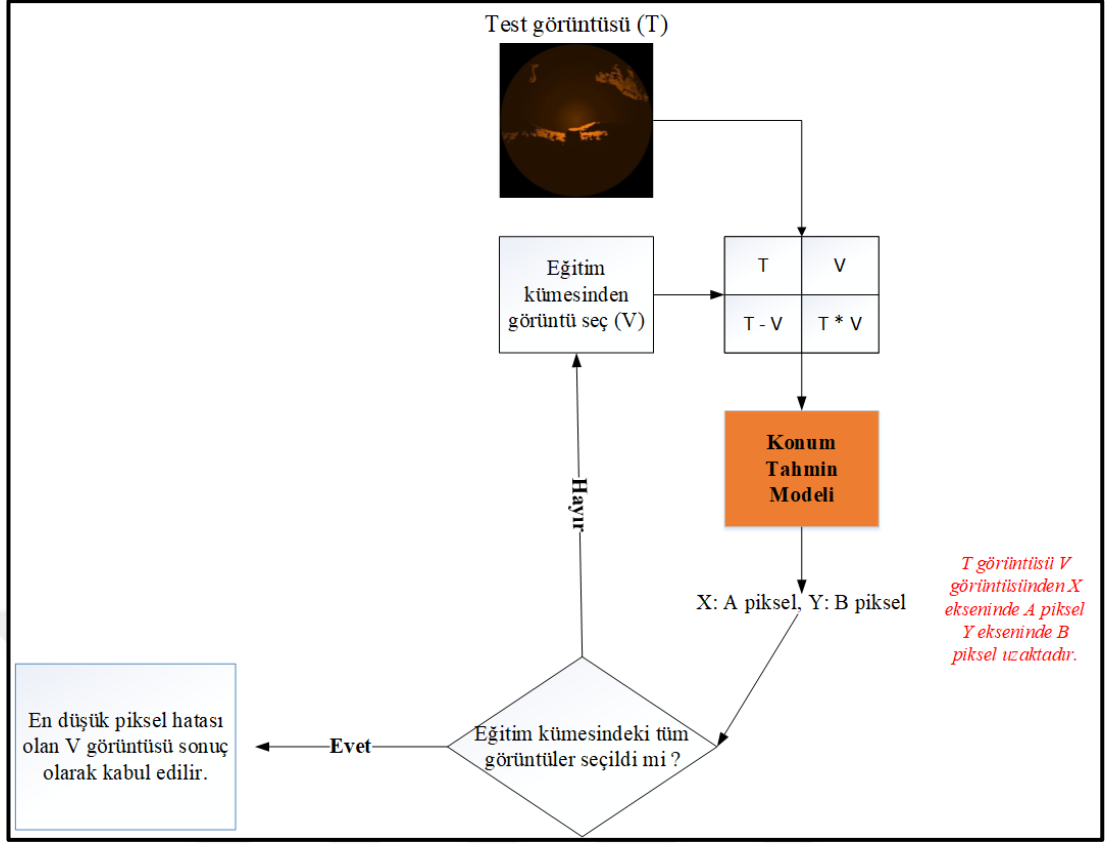
Tablo 2.4'te detayları yer alan modelden farklı olarak burada aşağıdaki gibi bir model kullanılmıştır. Tablo 2.4'te anlatılan modelin çıktı boyutu yön bilgisi olmadığından dolayı 15 olarak belirlenmiştir. Tablo 4.8'te yer alan modelin çıktı boyutu ise 58 olmaktadır. Son katman haricindeki diğer katmanlar ve değerler aynıdır.

Tablo 4.8: Yön bilgisi eklenerek konum tahmin modeli.

Radar görüntüleri kullanıldığında	Radar ve Uydu görüntüleri birlikte kullanıldığında
Input 128×128 Gray-Scale image	Input 192×192 Gray-Scale image
3×3 conv. 32 ReLU	
3×3 conv. 64 ReLU	
2×2 max-pooling	
Dropout 0.25	
128 FC ReLU	
Dropout 0.5	
58 sigmoid	


Tablo 4.8'de iki farklı senaryo için kullanılan model detayları yer almaktadır. İlk katmanlar girdi görüntülerinin olduğu katmandır. Yalnızca radar görüntüleri kullanıldığında girdi büyüklüğü 128×128 (Şekil 2.12), radar ve uydu görüntüleri birlikte kullanıldığında 192×192 (Şekil 2.15) olmaktadır. Girdi görüntüleri siyah-beyaz formattadır. Girdi görüntülerinin büyüklüğü haricinde diğer katman ve parametreler aynıdır. Görüntüden özniteliklerin çıkarılması için üzerinde iki ve üçüncü katmanlarda evrişim (konvolüsyon) işlemi uygulanmıştır. Devamında yer alan dropout işlemleri ise ezberlemenin önlenmesi için tercih edilmiştir. Son katmanda ki 58 değeri girdi görüntülerinin birbirlerine göre konumlarını ifade etmektedir.

Yön bilgisinin eklendiği durumlar için örnek test senaryosu Şekil 4.5'deki gibidir.




Şekil 4.4: Yön bilgisi eklenerek konum tahmini test senaryosu.

Şekil 4.4’de yer alan test senaryosu yalnızca radar görüntüleri kullanıldığı durum için geçerlidir. Veri kümesindeki her bir görüntü ile test görüntüsü Şekil 2.12’de belirtildiği üzere birleştirilir. Birleştirilen görüntüler tekli ve toplu olarak Konum Tahmin Modeline sorulur ve piksel cinsinden hata değerlerine göre küçükten büyüğe doğru sıralanır. En küçük hatalı tahmin sonuç kabul edilir. Yapılan deneylerdeki doğru örnekler Şekil 4.5 hatalı örnekler ise Şekil 4.6’ deki gibidir.




Şekil 4.5: Yön bilgisi eklenerek konum tahmini doğru örnekler (1 piksel ve altındaki hatalar sistem için başarılı / doğru kabul edilmektedir).

Şekil 4.5’da sistem tarafından doğru tahmin edilen örnekler gösterilmektedir. Görüntülerin üstlerinde yer alan sayısal ifadeler görüntülerin gerçek dünya enlem ve boylam değerlerini göstermektedir. Gerçekte iki görüntü arasındaki koordinat düzlemi X ve Y yönlerindeki uzaklıklar enlem ve boylam farklarından gerçek dünya uzaklıklarının bulunmasıyla hesaplanmaktadır. Piksel cinsinden toplam hata değerlerinin düşük olması sevindiricidir. Problem tanımında belirlenen başarıım kriteri olan 1 piksel ifadesinin karşılandığı görülmektedir.



Şekil 4.6: Yön bilgisi eklenerek konum tahmini hatalı örnekler (1 piksel üstündeki hatalar sistem için başarısız /hatalı kabul edilmektedir.).




Şekil 4.7: X yönündeki örnek hata matrisi.

Deneylerde kullanılan veri kümesi eğitim ve test olmak üzere iki parçadan oluşmaktadır. Bu kümeler birbirlerinden farklıdır. Tablo 4.9’ da 7.satırda yer alan deneye ait x ve y yönlerindeki hata matrisleri Şekil 4.7 ve Şekil 4.8’deki gibidir.

Tablo 4.9: Yön bilgisi eklenerek konum tahmini deney sonuçları.

Epok	Sınıf Sayısı	Veri kümesi	Eğitim veri sayısı	Test veri sayısı	Test doğruluk oranı	Ortalama hata (piksel)
3	10	Büyük (RO)	~93K	~21K	0.96179	3.252
3	15	Büyük (RO)	~80K	~18K	0.97294	2.324
3	15	Büyük (RO)	~93K	~21K	0.97286	2.120
10	15	Büyük (RO)	~67K	~15K	0.97581	1.638
10	15	Büyük (RO)	~108K	~24K	0.97777	1.312
10	15	Büyük (RO)	~150K	~36K	0.97879	1.279
10	15	Büyük (RO)	~250K	~60K	0.97916	1.266
12	15	Büyük (R)	~200K	~27K	0.98042	1.046
10	15	Büyük (R)	~167K	~23K	0.97975	1.062
15	15	Büyük (R)	~250K	~34K	0.98066	0.871
30	15	Küçük (R)	~75K	~10K	0.99842	0.300



Şekil 4.8: Y yönündeki örnek hata matrisi.

Bu bölümde yapılan deneylerde veri kümesi eğitim ve test olarak iki parçaya ayrılırken k katlamalı çapraz doğrulama kullanılmıştır. K katlamalı çapraz doğrulama yapmadan önce veri kümesi tamamen karıştırıldı. Bu durumda eğitim ve test kümesinde aynı sınıfa ait görüntüler bulunma ihtimali çok yüksek olacaktır. Ortalama piksel hatasının bu kadar iyi çıkmasında bu sebep etkili olmuştur. Bu deneylere ek olarak toplamda 3346 sınıfı 3000 sınıf ve 346 sınıf olarak iyi parçaya ayırıp eğitim ve test kümesi olarak kabul eden deneyler gerçekleştirdik. Bu şekilde yaparak test kümesinde yer alan bir görüntünün eğitim kümesinde olmaması sağlandı.

Tablo 4.10: Yön bilgisi eklenerek konum tahmini deney sonuçları (Eğitim ve Test kümesi tamamen farklı seçilmiştir. Aynı sınıftan herhangi bir görüntü bulunmamaktadır).

Epok	Sınıf Sayısı	Veri kümesi	Eğitim veri sayısı	Test veri sayısı	Test doğruluk oranı	Ortalama hata (piksel)
15	15	Büyük (RO)	~160K	~33K	0.97293	4.422
15	15	Büyük (RO)	~240K	~50K	0.97352	4.108
20	15	Büyük (RO)	~400K	~50K	0.97443	4.129

Sonuçların Tablo 4.9 'da yer alan sonuçlardan daha kötü olması beklenmektedir. Elde edilen sonuçlar Tablo 4.10 'daki gibidir.

Tablo 4.10' a bakıldığında ortalama piksel değerlerinin arttığı görülmektedir. Eğitim ve Test kümesinin tamamen farklı seçilmesinden kaynaklı olduğunu düşünüyoruz. Öyle ki yeni gelen görüntüyü konum tahmin modeli daha önceden hiç görmemiş oluyor ve bu şekilde tahmin etmeye çalışıyor. Bu sebeple başarımın düşük olması kabul edilebilir.

Deneyler iki açıdan ele alınmıştır. İlki veri kümesinin tamamen karıştırılıp k katlamalı çapraz doğrulama yöntemi ile eğitim ve test kümelerine ayrıştırılıp gerçekleştirilmesidir. İkincisi ise toplamda yer alan 3346 sınıflı veri kümesi 3000 ve 346 olacak şekilde el yardımıyla ikiye ayrıştırılıp eğitim ve test kümesi olarak seçilmesidir. Birinci durumunda başarımın yüksek çıkması beklenmektedir. Öyle ki veri kümesi karıştırıldığından dolayı eğitim kümesindeki bir görüntü ile aynı sınıfta yer alan bir görüntü test kümesinde olabilir. İkinci durumda böyle bir şey söz konusu değildir.

Deneylerde iki farklı veri kümesi kullanılmıştır. Bunlar büyük ve küçük şeklinde isimlendirilmiştir. Büyük veri kümesi içerisinde 3346 sınıftan, küçük veri kümesi içerisinde 500 sınıf barındırmaktadır. Yalnızca radar görüntülerinin kullanıldığı (R) ve uydu görüntüleri ile birlikte kullanıldığı (RO) durumlar için deneyler yapılmıştır. Deneylere ait sonuçlar Tablo 4.9'da görüldüğü gibidir. Deneyler sonucunda aşağıdaki yargılara varılmıştır.

- Epok değeri arttıkça ortalama hata değeri azalmaktadır. (Belirli bir değere kadar bu azalmanın olacağı varsayılmaktadır. Sonrasında sabit gideceği düşünülmektedir.)
- Büyük veri kümesi kullanıldığı durumlardaki ortalama hata değeri küçük veri kümesi kullanıldığı durumlardakine göre çok daha yüksektir. Bunun sebebi sınıf sayısının çok olmasıdır. Daha az sınıfı öğrenmesi daha kolay olmuştur. Kullanılan ağ modeli biraz daha büyütülerek bu değerler iyileştirilebilir.
- Eğitimde kullanılan veri sayısı arttıkça ortalama hata değeri azalmaktadır.
- Eğitim ve Test kümelerini seçerken birbirlerinden tamamen bağımsız kümeler seçildiğinde başarımın düştüğü gözlemlenmiştir. Tamamen bağımsız seçmek,

yeni gelen görüntünün konum tahmin modeli tarafından daha önce görülmediği anlamına gelmektedir.


Hedeflenen başarımların kriteri 1 olarak kabul edilmişti. Tablo 4.9’da yer alan sonuçlar başarımların kriterine ulaşıldığını göstermektedir.

4.3.3 Artırımsal konum tahmini / iyileştirme

Bölüm 4.3.2’de yön bilgisi eklenerek konum tahmini bölümünde gelen test görüntüsünün eğitim kümesindeki tüm görüntülerle karşılaştırdıktan sonra sonuca vardığı anlatıldı. Bu şekilde yapılan bir işlem gerçek zamanlı olması durumunda iyi olmaz. Bu sebeptendir ki bu süre ve işlemin kısaltılması için ek geliştirmeler yapılmıştır. Burada tüm görüntüler yerine rastgele bir görüntü seçilir. Konum Tahmin Modeli (KTM) n’den gelen cevaba göre seçilen görüntünün koordinat bilgisine KTM ‘den gelen uzaklık değerleri eklenerek yeni bir görüntü seçilir. Bu işlem hata piksel değeri 1’ den küçük oluncaya kadar veya belirli bir işlem sayısı kadar tekrar edilir.

Yapılan deneyler sonucunda elde edilen sonuçlar gösteriyor ki; test görüntüsünü bütün eğitim kümesiyle karşılaştırmak ile bu şekilde rastgele görüntü seçip karşılaştırmak arasında ortalama piksel hatası açısından fark yok denecek kadar az ve hız açısından yaklaşık olarak 40 kat fark etmektedir.

Yalnızca radar görüntülerinin kullanıldığı durum için örnek test senaryosu Şekil 4.9’deki gibidir.




Şekil 4.9: Artırımsal konum tahmini için yalnızca radar görüntülerinin kullanıldığı örnek test senaryosu.

Şekil 4.9’de yer alan test senaryosu işlem adımlarını içermektedir. Test görüntüsü Bölüm 4.3.2’de eğitim kümesinde yer alan bütün görüntülerle karşılaştırıldıktan sonra sonucu tahmin ediyordu. Burada ise kümedeki tüm elemanlarla teker teker karşılaştırmak yerine rastgele bir görüntü seçilerek işleme başlanıyor. Bu görüntü ile test görüntüsü birleştirilip KTM ‘ye veriliyor. Sonuç hatası

piksel cinsinden 1' den küçük ise doğru sonuç bulunmuştur kabul edilip işlem sonlandırılır. Aksi durumda ise tekrardan yeni bir rastgele görüntü seçilerek işlem adımları tekrarlanır. Bu işlemin tüm kümeye kadar devam etmemesi için belirli bir özyineleme ile sınırlandırılır. Bizim yaptığımız deneylerde bu sınır 100 olarak kabul edildi.

Radar ve uydu görüntülerinin birlikte kullanıldığı durum için örnek test senaryosu Şekil 4.10'daki gibidir.



Şekil 4.10: Artırımsal konum tahmini örnek test senaryosu.

Şekil 4.10'da yer alan örnek test senaryosu Şekil 4.9'de yer alan senaryodan farklı olarak uydu görüntülerini de içermektedir. Yukarıda belirtildiği gibi kümedeki tüm elemanlarla teker teker karşılaştırmak yerine rastgele bir görüntü seçilerek işleme

başlanıyor. Bu görüntü ile test görüntüsü birleştirilip KTM 'ye veriliyor. Sonuç hatası piksel cinsinden 1' den küçük ise doğru sonuç bulunmuştur kabul edilip işlem sonlandırılır. Aksi durumda ise tekrardan yeni bir rastgele görüntü seçilerek işlem adımları tekrarlanır. Bu işlemin tüm kümeye kadar devam etmemesi için belirli bir özyineleme ile sınırlandırılır. Bizim yaptığımız deneylerde bu sınır 100 olarak kabul edildi.


Tablo 4.11: Artırımsal konum tahmini deney sonuçları.

Epok	Eğitim Veri Sayısı	Test Veri Sayısı	Test Doğruluk Oranı	Test Hata Oranı	X yönünde Ortalama Hata Değeri	Y yönünde Ortalama Hata Değeri
15	~562K	~18K	0.9802	0.0428	0.781	0.273
10	~401K	~18K	0.9790	0.0458	0.950	0.282
5	~562K	~18K	0.9785	0.0471	0.842	0.300

Deney sonuçları Tablo 4.11'de yer almaktadır. Deneylerde veri kümesi olarak 3346 sınıftan oluşan küme kullanılmıştır. Epok seviyesi ve eğitim veri sayısı değiştirilerek modelin başarımı hesaplanmıştır. Tabloda yer alan X yönündeki ortalama hata ve Y yönündeki ortalama hata toplamı sistemin genel ortalama hata değeridir. Bu deneyler sonucunda bütün veri kümesiyle teker teker karşılaştırmaya gerek kalmadan bu şekilde rastgele görüntüler seçerek yapılan karşılaştırma sonuçları Tablo 4.9'daki sonuçlardan daha iyidir. İşlem süresi bakımından rastgele görüntüler seçerek yapılan karşılaştırma tüm kümeyle karşılaştırma işleminden yaklaşık olarak 7-8 kat daha hızlı sürmektedir.

5. SONUÇLAR


Tez çalışmasını üç aşamaya ayırabiliriz. Birinci aşama simülasyon uygulamasından elde edilen radar ve Google haritalar servisinden elde edilen uydu görüntülerinden oluşturulan veri kümesi üzerinde derin öğrenme yöntemlerinin uygulanabilirliğinin gözlemlenmesidir. Bunun için evrimsel sinir ağları ile sınıflandırma problemi uygulandı. Sonuçta derin öğrenme yöntemlerinin veri kümesi üzerinde uygulanabildiği ve sınıflandırma yapılabildiği gözlemlendi.



Şekil 5.1: Sonuçlar Sınıflandırma örnek.

Şekil 5.1 de yer alan sınıflandırma senaryosudur. Sınıflandırma modülüne girdi olan görüntü girmekte ve çıktı olarak 0 ile 3346 arasında bir sınıf değeri çıkmaktadır. Bu sonuç konum tahmininde kullanılamaz. Öyle ki sınıflandırma modülünün çıktısı sabittir ve değişmez. Fakat deniz araçlarının hareketli oldukları göz önünde bulundurulduğundan bu yöntem yalnızca mevcut veri kümesi üzerinde derin öğrenme yöntemlerinin kullanılabilirliğinin gözlemlenmesi açısından gerçekleştirilmiştir.

İkinci aşamada yapılan literatür çalışmalarında metrik öğrenme problemlerinde genellikle ikiz ağlar kullanıldığı gözlemlendi. Bu sebeple konum tahmin problemi için ikiz ağlar yöntemi uygulandı. Burada ikiz ağlar yönteminde sisteme girdi olarak görüntüleri iki farklı koldan verip belirli bir katmanda sonuçları birleştirip tek bir çıktı olarak veriyoruz. Yapılan araştırmalarda girdi görüntülerinin etiketlenmesinde aynı (1) ve farklı (0) olarak etiketlendiği gözlemlendi. Fakat bu şekilde işaretleme yapıldığında verilen bir görüntünün gerçek dünya koordinatının bulunmasına yönelik bir sonuç üretmediği sadece diğer görüntünün kendisi ile aynı yani aynı sınıfta veya farklı olduğu bilgisi elde edildi.




Şekil 5.2: Sonuçlar İkiz Ağlar Örnek.

Şekil 5.2’de gösterilen ikiz ağlar modülü girdi olarak 2 görüntü almakta ve çıktı olarak 0 (farklı) veya 1 (aynı) sonucunu üretmektedir. Literatürde yapılan araştırmalarda görüntüler arasındaki benzerlik metriğinin öğrenilmesi problemlerinde ikiz ağlar modelinin kullanılarak çözüme ulaşıldığı kanısı edinildi. Aynı yöntemin kendi problemimiz üzerinde uygulanmaya çalışıldığında ortaya benzer veya farklı olduğunu tahmin eden bir ürün çıktı görüldü. Fakat burada benzer veya farklı ifadesinin bir derecesi bulunmamaktadır. Gerçek zamanlı bir konum tahmininde benzer veya farklıdan daha konumu bilinmeyen görüntü konumu bilinen görüntüden belirli bir mesafe uzaklıktadır şeklinde varsayımlar kabul görmektedir.

Üçüncü aşamada İkiz ağlar yönteminden istenilen başarı elde edilemediğinden görüntüler arasındaki benzerlik metriğinin öğrenilmesinde bizim önerdiğimiz görüntülerin bir ön işleminden geçirilerek farklı ve çarpımlarını alıp sisteme tek bir görüntü olarak vermek fikrini uyguladık. Burada görüntüleri etiketleme aşamasında gerçek dünya koordinatlarını kullanarak uzaklıklarını bulup, bu uzaklıklara karşılık gelen piksel değerlerini sınıf etiketi olarak kabul ettik. Böylelikle iki görüntü sisteme test için verildiğinde sonuç olarak bir görüntünün diğer görüntüye göre konumu hakkında bilgi sahibi olabildik. Öyle ki birinci görüntü ikinci görüntünün koordinat düzlemine göre x piksel solunda ve y piksel aşağıda gibi. Bu yöntem sonucunda

yapılan deneylerde doğruluk oranından çok ortalama piksel hatası referans alındı ve hedef olarak 1 piksel ve altı başarılı olarak kabul edildi.



Şekil 5.3: Sonuçlar Evrişimsel katmanlı metrik öğrenme örnek.

Şekil 5.3’de gösterilen evrişim katmanlı metrik öğrenme modeli girdi olarak iki görüntü almaktadır. Çıktı olarak test görüntüsünün referans görüntüye olan koordinat düzlemindeki X ve Y yönlerindeki görüntü piksel uzaklığını karşılayan 0 ile 15 arasındaki sınıflardan birini döndürmektedir. Sınıflandırma ve ikiz ağlar yönteminin aksine burada konumu bilinmeyen test görüntüsü konumu bilinen referans görüntüye göre belirli bir uzaklık kestirimi yapılabilmektedir. Öyle ki her bir pikselin gerçek dünya karşılığı bilindiğinden piksel farkı konumu bilinen görüntüye eklenerek test görüntüsünün yaklaşık konumu bulunabilmektedir.

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 kullanılabilecek bir ürün ortaya çıkacaktır.

6. ÖNERİLER

Tez kapsamında üzerinde çalışılan radar ve uydu görüntüleri çözünürlük bakımından yeteri kadar yüksek değildir. Görüntüler arasındaki benzerliklerin daha iyi bulunabilmesi ve başarımın artırılabilmesi amacıyla daha yüksek çözünürlüklü radar ve uydu görüntüleri temin edilmelidir. Bu çalışmanın devamında yüksek çözünürlüklü görüntülerin toplanmasıyla yeni bir veri kümesi oluşturulup mevcut sistemin başarımı gözlemlenecektir. Yapılan deneylerde eğitim veri sayısının artırılmasıyla başarımın arttığı gözlemlenmiştir. Fakat eğitim veri sayısının artması eğitim süresini uzatmaktadır. Bu sebeple eğitim ve test aşamalarındaki sürenin kısaltılması ve başarımın artırılması için daha performanslı donanım temin edilmelidir. Performanslı donanım üzerinde eğitim veri kümesini artırıp başarımdaki değişim gözlemlenecektir. Devamında ise tekrarlayan sinir ağları kullanılarak tahmin işlemi gerçekleştirilecektir. Tekrarlayan sinir ağlarına zaman bilgisi de eklenecektir. Bu sayede daha doğru sonuçlar elde edileceği ve gerçek zamanlı kullanım oluşturabileceği hedeflenmektedir.

KAYNAKLAR

- [1] Nalbantoglu V., Seymen B., (2007), “Ataletsel Seyrüsefer Sistemleri”, Mühendis ve Makina, 48(566), 7–13.
- [2] Web 1, (2017), https://en.wikipedia.org/wiki/Global_Positioning_System, (Erişim Tarihi: 10/10/2017).
- [3] National Research Council, (1995), “The Global Positioning System: A Shared National Asset”, ISBN 0-309-05283-1, The National Academies Press.
- [4] Web 2, (2017), <http://tr.wikipedia.org/wiki/Radar>, (Erişim Tarihi: 16/08/2017).
- [5] Guesalaga A., (2004), “Recursive estimation of radar biases using electronic charts”, IEEE Transactions on Aerospace and Electronic Systems, 40 (2), 725-733.
- [6] Torres-Torriti M., (2007), “Automatic ship positioning and radar biases correction using the hausdorff distance”, 10th International Conference on Information Fusion, 1-8, Quebec, Canada, 9-12 July.
- [7] Olszewska J. I., Wilson D., (2012), “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, 91-96, Lisbon, Portugal, 13-15 June.
- [8] Aytac A. E., Aksoy O., Akgul Y.S., (2014), “Ship positioning by matching radar images and map data”, 22nd Signal Processing and Communications Applications Conference(SIU), 1423-1426, Trabzon, Turkey, 23-25 April.
- [9] Weyand T., Kostrikov I., Philbin J., (2016), “PlaNet - Photo Geolocation with Convolutional Neural Networks”, In European Conference on Computer Vision (ECCV), 37-55, Amsterdam, Netherlands, 8-16 October.
- [10] Krizhevsky, A., Sutskever I., Hinton G. E., (2012), “ImageNet classification with deep convolutional neural networks”, In Advances in neural information processing systems, 1097-1105, Lake Tahoe, Nevada, The United States of America, 3-8 December.
- [11] Cho K., Merriënboer B., Gulcehre C., Bougares F., Schwenk H., Bengio Y., (2014), “Learning phrase representations using RNN encoder-decoder for statistical machine translation”, Conference on Empirical Methods in Natural Language Processing, 1724-1734, Doha, Qatar, 26-28 October.
- [12] Sutskever I., Vinyals O., Le Q. V., (2014), “Sequence to sequence learning with neural networks”, Advances in Neural Information Processing Systems, 3104–3112, Montreal, Canada, 8-13 December.

- [13] Graves A., (2013), “Generating sequences with recurrent neural networks”, arXiv preprint arXiv:1308.0850.
- [14] Sutskever I., Martens J., Hinton G. E., (2011), “Generating text with recurrent neural networks”, Proceedings of the 28th International Conference on Machine Learning, 1017-1024, Bellevue, Washington, The United States of America, 28 June – 2 July.
- [15] Chopra S., Hadsell R., LeCun Y., (2005), “Learning a similarity metric discriminatively, with application to face verification”, In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR-05), 349–356, San Diego, CA, 20-25 June.
- [16] Hoffer, E., Ailon, N., (2015), “Deep metric learning using triplet network”, In International Workshop on Similarity-Based Pattern Recognition, 84-92, Copenhagen, Denmark, 12-14 October.
- [17] L. Yang, R. Jin., (2007), “Distance Metric Learning: A Comprehensive Survey”, Technical report, Department of Computer Science and Engineering, Michigan State University, The United States of America.
- [18] Web 3, (2018), <https://leagueofextraordinarytechnicians.wikispaces.com/Inertial+Navigation+Systems+-+Operation+%26+Testing>, (Erişim Tarihi: 21/03/2018).
- [19] Web 4, (2018), <http://nbtimes.it/prime/2786/2010-linizio-della-fine-del-gps.html>, (Erişim Tarihi: 21/03/2018).
- [20] Web 5, (2018), <http://www.pilliblog.com/pilli/gps-nedir-ve-nasil-calisir>, (Erişim Tarihi: 21/03/2018).
- [21] Bromley, J., Bentz, J. W., Bottou, L., Guyon, I., LeCun, Y., Moore, C., Sackinger, E., Shah R., (1993), “Signature verification using a Siamese time delay neural network”, International Journal of Pattern Recognition and Artificial Intelligence, 7(4), 669–688.
- [22] Yin W., Schutze H., Xiang B., Zhou B., (2015), “ABCNN: Attention-Based Convolutional Neural Network for Modeling Sentence Pairs”, Transactions of the Association for Computational Linguistics, 4, 259-272.
- [23] Web 6, (2018), https://www.globalspec.com/learnmore/sensors_transducers_detectors/tilt_sensing/inertial_gyros, (Erişim Tarihi: 21/03/2018).
- [24] Web 7, (2018), https://www.tensorflow.org/tutorials/image_recognition, (Erişim Tarihi: 07/06/2018).

ÖZGEÇMİŞ

Muhammed Maruf KILIÇ 1993 yılında Erzincan’da doğdu. 2010 yılında başladığı Gebze Teknik Üniversitesi Mühendislik Fakültesi Bilgisayar Mühendisliği Bölümünü 2015 yılında bölüm ikincisi olarak başarıyla tamamlayarak aynı yıl yüksek lisans eğitimine Gebze Teknik Üniversitesi Fen Bilimleri Enstitüsü Bilgisayar Mühendisliği Anabilim Dalında başladı. 2015 yılından bu yana TÜBİTAK BİLGEM’de Görüntü Kıymetlendirme / Kitle kaynak konularında araştırmacı olarak çalışmaktadır.



EKLER

Ek A: Tez Çalışması Kapsamında Yapılan Yayınlar

Kilic M. M., Akgul Y.S., (2018), "Ship Location Estimation from Radar and Optic Images using Metric Learning", IEEE Signal Processing and Communications Applications Conference (SIU), İzmir, 2-5 May.

