

**TOBB EKONOMİ VE TEKNOLOJİ ÜNİVERSİTESİ**  
**FEN BİLİMLERİ ENSTİTÜSÜ**

**KÜRESEL KONUMLAMA SİSTEMİ KAYBI OLAN ORTAMLARDA  
İNSANSIZ HAVA ARAÇLARI İÇİN GELİŞTİRİLEN ALTERNATİF  
SEYRÜSEFER TEKNİĞİ**



**YÜKSEK LİSANS TEZİ**

**Çağla ŞAHİN**

**Elektrik ve Elektronik Mühendisliği Anabilim Dalı**

**Tez Danışmanı: Doç. Dr. İmam Şamil YETİK**

**TEMMUZ 2020**

## TEZ BİLDİRİMİ

Tez içindeki bütün bilgilerin etik davranış ve akademik kurallar çerçevesinde elde edilerek sunulduğunu, alıntı yapılan kaynaklara eksiksiz atıf yapıldığını, referansların tam olarak belirtildiğini ve ayrıca bu tezin TOBB ETÜ Fen Bilimleri Enstitüsü tez yazım kurallarına uygun olarak hazırlandığını bildiririm.

Çağla Şahin

## ÖZET

Yüksek Lisans Tezi

KÜRESEL KONUMLAMA SİSTEMİ KAYBI OLAN ORTAMLARDA İNSANSIZ  
HAVA ARAÇLARI İÇİN GELİŞTİRİLEN ALTERNATİF SEYRÜSEFER TEKNİĞİ

Çağla Şahin

TOBB Ekonomi ve Teknoloji Üniversitesi  
Fen Bilimleri Enstitüsü  
Elektrik ve Elektronik Mühendisliği Anabilim Dalı

Tez Danışmanı: Doç. Dr. İmam Şamil Yetik

Tarih: Temmuz 2020

İnsanlı ve insansız uçaklarda küresel konumlama sistemindeki (GPS) kayıp, uçağın seyrüseferini etkilemektedir, fakat insanlı uçaklarda pilot tarafından seyrüsefer devam edebilirken, insansız uçaklarda uçağın kırımı gibi bir sonuç ile karşılaşılabilir. Bu sebeple, küresel konumlama sistemi olmayan ortamlarda uçakların seyrüseferlerine devam edememesi en sık görülen seyrüsefer sorunlarından birisidir. GPS kaybı durumunda, ataletsel seyrüsefer sistemi (INS) ile uçaklar seyrüseferine bir süre devam edebilse bile, uçaklardaki sürüklenmeden kaynaklı konumundaki hata gittikçe artmaktadır ve uçak takip edebilmesi gereken rotadan uzaklaşmaktadır. Bu sebeple bu tezde GPS bilgisinden beslenmeyen uçak üzerine yeryüzünü görece şekilde yerleştirilmiş faydalı yük kamerası ile insansız hava aracının (İHA) konumunu bilmesini sağlayan bir sistem geliştirilmiştir. Bir tanesi uçak üzerine yerleştirilmiş faydalı yük kamerasından, bir diğeri de uydudan alınmış GPS konumu bilinen görsellerin olduğu iki adet görüntü verileri bulunmaktadır. Çeşitli öznitelik çıkarma sinir ağı modelleri ve iki görüntü seti içerisinde normalleştirilmiş değişken ortak enformasyon kullanılarak İHA'nın konumunun tespit edebilen bir yöntem geliştirilmiştir. Uydudan gelen görüntü setindeki görseller GPS konumları ile birlikte etiketlenip, İHA aracına verilmektedir. Bu iki görüntü seti öznitelik belirleme ve sınıflandırma için kullanılan sinir ağından geçirilip, öznitelikleri belirlendikten sonra, bu öznitelikler tasarlanan iki adet sinir ağından daha

geçirilmektedir. İlk sinir ađında geçirildikten sonra, uydu görsellerinin İHA'dan gelen görsellerin içinde olup olmadığı tespit edilip, eđer İHA'dan gelen görüntü içerisinde uydu görselleri var ise, ikinci sinir ađından daha geçirilip, İHA konumunun uydu görselleri üzerinden eşleştirilmesi yapılmaktadır. İkinci sinir ađından alınan sonuçlara ile birlikte iki görüntü seti içerisinde normalleştirilmiş deđişken ortak enformasyon kullanılmaktadır. İkinci sinir ađından gelen konum bilgisi sonucuna, normalleştirilmiş ortak enformasyon hesabında daha fazla ađırlık verilerek, eşleşmenin maksimum olduđu bölge aranmaktadır. GPS kaybı durumunda, İHA'dan alınan görseller içerisinde önceden verilmiş etiketlenmiş uydu görselleri aranıp ve uydu görselinden gelen obje, İHA görüntüsü üzerinden tespit edildiđi anda, uydu görselinin GPS bilgisi, insansız hava aracına verilmektedir. Önerilen algoritmayı test etme amacıyla İHA tarafından toplanmış görüntüler ve uydudan alınmış görseller içeren iki veri seti bulunmuş ve etiketleme işlemleri yapılmıştır. Önerilen algoritma farklı öznitelik çıkarma sinir ađları kullanılarak, İHA görüntülerinin birleştirildiđi ve birleştirilmediđi senaryolarda test edilmiştir. Ortak enformasyon işlemi sonrasında elde edilen sonuçların, sinir ađının çıktıklarına kıyasla, ortalama kareli hata ve kesişim kümesi oranları bakımından daha üstün olduđu gözlemlenmiştir.

**Anahtar Kelimeler:** Görüntü işleme, Derin öğrenme, Alternatif seysüresefer sistemi, İnsansız hava araçları

## ABSTRACT

Master of Science

### ALTERNATIVE NAVIGATION METHOD FOR UNMANNED AERIAL VEHICLES IN GLOBAL POSITIONING SYSTEM DENIED ENVIRONMENTS

Çağla Şahin

TOBB University of Economics and Technology  
Institute of Natural and Applied Sciences  
Department of Electrical and Electronics Engineering

Supervisor: Assoc. Prof. İmam Şamil Yetik

Date: July 2020

Navigation system for both unmanned and manned aerial vehicles are affected negatively in Global Positioning System (GPS) denied environment. Although pilot can take control on navigation in GPS-denied environment for manned aerial vehicles, for unmanned aerial vehicles (UAV), GPS-denied environment can cause catastrophic solutions. Because of this reason, it is one of the most common problems for aircrafts to continue navigation in GPS denied environment. In the case of GPS loss, even if the aircraft can continue its navigation for a while with the inertial navigation system (INS), the error due to the drift increases and the aircraft is moving away from the route it should follow. For this reason, a system that does not feed from GPS information has been developed and it enables the UAV to know the location of the aircraft with a payload camera placed on the UAV. There are two types of image data, one of which is from the payload camera placed on the aircraft, and the other is satellite image set which has GPS information for each satellite image. The position of the UAV is determined by using the feature extraction neural network model and normalized variant mutual information within two image sets. Images from the satellite image set are labelled with GPS information and given to the UAV. After these two sets of images are passed through the different feature extraction neural network models and classification and feature extraction is done for the image datasets, these features are passed through

two more designed neural network. After passing on the first neural network, it is determined whether the satellite images are in the images coming from the UAV or not, and if there are satellite images in the image coming from the UAV, the second neural network is passed through and the UAV location is matched over the satellite images. Along with the results from the second neural network, normalized variant mutual information is used within the two image sets. In order to find the region where the match is maximum, maximum of normalized variant mutual information between these two images is calculated by giving more weight of the results from second network. In case of GPS loss, the developed algorithm starts to work and satellite images which have GPS information are searched in UAV camera images. If the UAV is in that area, GPS information from satellite image is given to the UAV. To test our algorithm, we find two image dataset, where one consists of images taken from UAV and the other one consists of the satellite images, and labelled these images. We conduct various experiments under different scenarios such as different feature extractor networks, stitched/unstitched input images on the UAV side. We observe that the performance after the mutual information module is higher compared to the performance of the neural network in terms of both mean squared error and intersection of union.

**Keywords:** Image registration, Deep learning, Alternative navigation system, Unmanned aerial vehicles

## TEŐEKKÜR

Çalıőmalarım boyunca deęerli yardım ve katkılarıyla beni yönlendiren hocam Doç. Dr. İmam Őamil YETİK'e, kıymetli tecrübelerinden faydalandığım TOBB Ekonomi ve Teknoloji Üniversitesi Elektrik Elektronik Mühendislięi Bölümü öğretim üyelerine ve araştırma bursu sağladığı için TOBB Ekonomi ve Teknoloji Üniversitesi'ne teşekkür ederim. Ayrıca, destekleriyle her zaman yanımda olan anneme, babama, kardeşime ve sevgili eşim Onur'a kıymetli desteklerinden dolayı çok teşekkür ederim.





## İÇİNDEKİLER

	<u>Sayfa</u>
<b>ÖZET</b> . . . . .	<b>iv</b>
<b>ABSTRACT</b> . . . . .	<b>vi</b>
<b>TEŞEKKÜR</b> . . . . .	<b>viii</b>
<b>İÇİNDEKİLER</b> . . . . .	<b>ix</b>
<b>ŞEKİL LİSTESİ</b> . . . . .	<b>xi</b>
<b>ÇİZELGE LİSTESİ</b> . . . . .	<b>xiii</b>
<b>KISALTMALAR</b> . . . . .	<b>xiv</b>
<b>1. GİRİŞ</b> . . . . .	<b>1</b>
1.1 Literatür Araştırması . . . . .	1
1.2 Tezin Amacı . . . . .	3
1.3 Tezin Organizasyonu . . . . .	3
<b>2. GNSS SİSTEMLERİ VE INS</b> . . . . .	<b>5</b>
2.1 GPS . . . . .	6
2.2 Glonass . . . . .	6
2.3 Galileo . . . . .	7
2.4 INS . . . . .	7
<b>3. GPS KAYBI YAŞANAN ORTAMLARDA KONUM BELİRLEME YÖN- TEMİ</b> . . . . .	<b>9</b>
3.1 Sinir Ağına Dayalı Seyrüsefer Sistemi . . . . .	10
3.1.1 Sinir ağı tabanlı öznitelik çıkarma modülü . . . . .	10
3.1.2 Sinir ağı tabanlı obje tespit modülü . . . . .	12
3.1.3 Sinir ağı tabanlı imge karşılaştırma modülü . . . . .	13
3.2 İmge Birleştirme . . . . .	13
3.3 Ortak Enformasyon . . . . .	15
3.3.1 Ortak enformasyon tarihçesi . . . . .	15
3.3.2 Ortak enformasyon tanımı . . . . .	15
3.3.3 Ortak enformasyon ile seyrüsefer sistemi . . . . .	17
3.4 Veri Seti . . . . .	18
3.4.1 Uydudan alınan veri seti . . . . .	18
3.4.2 İHA'dan alınan veri seti . . . . .	18
<b>4. SİMÜLASYON ORTAMI VE SONUÇLARIN ANALİZİ</b> . . . . .	<b>19</b>
4.1 Sinir Ağı Eşleşme Sonuçları . . . . .	19
4.1.1 Alexnet kullanılan sinir ağı eşleşmesi . . . . .	19
4.1.2 VGG kullanılan sinir ağı eşleşmesi . . . . .	24
4.1.3 MobileNet kullanılan sinir ağı eşleşmesi . . . . .	28
4.1.4 AlexNet kullanılan ortak enformasyon eşleşmesi . . . . .	32

4.1.5 VGG kullanılan ortak enformasyon eşleşmesi . . . . .	33
4.1.6 MobileNet kullanılan ortak enformasyon eşleşmesi . . . . .	34
<b>5. SONUÇ . . . . .</b>	<b>37</b>
<b>KAYNAKLAR . . . . .</b>	<b>38</b>
<b>ÖZGEÇMİŞ . . . . .</b>	<b>42</b>



## ŞEKİL LİSTESİ

	<u>Sayfa</u>
Şekil 2.1: Hava aracı dönüş eksenleri . . . . .	7
Şekil 3.1: Algoritmanın genel mimarisi. . . . .	9
Şekil 3.2: Öznitelik çıkarma işlemi. . . . .	13
Şekil 4.1: Alexnet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-kesişim kümesi grafiği. . . . .	20
Şekil 4.2: Alexnet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-ortalama kareli hata grafiği. . . . .	20
Şekil 4.3: Alexnet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-kesişim kümesi grafiği. . . . .	21
Şekil 4.4: Alexnet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-ortalama kareli hata grafiği. . . . .	21
Şekil 4.5: Alexnet ile ortak enformasyon bloğuna girmeden önce elde edilen uydu ve kamera görüntüsü eşleşmesi. . . . .	22
Şekil 4.6: Google Earth üzerinden alınan bir bina görseli. . . . .	23
Şekil 4.7: Google Earth üzerinden alınan bir bina görseli. . . . .	23
Şekil 4.8: VGG16 ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-kesişim kümesi grafiği. . . . .	25
Şekil 4.9: VGG16 ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-ortalama kareli hata grafiği. . . . .	25
Şekil 4.10: VGG16 ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-kesişim kümesi grafiği. . . . .	26
Şekil 4.11: VGG16 ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-ortalama kareli hata grafiği. . . . .	26
Şekil 4.12: VGG16 ile ortak enformasyon bloğuna girmeden önce elde edilen uydu ve kamera görüntüsü eşleşmesi. . . . .	27
Şekil 4.13: Google Earth üzerinden alınan bir bina görseli. . . . .	27
Şekil 4.14: MobileNet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-kesişim kümesi grafiği. . . . .	28
Şekil 4.15: MobileNet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-ortalama kareli hata grafiği. . . . .	29
Şekil 4.16: MobileNet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-kesişim kümesi grafiği. . . . .	29
Şekil 4.17: MobileNet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-ortalama kareli hata grafiği. . . . .	30
Şekil 4.18: MobileNet ile ortak enformasyon bloğuna girmeden önce elde edilen uydu ve kamera görüntüsü eşleşmesi. . . . .	31

Şekil 4.19: Google Earth üzerinden alınan bir bina görseli. . . . .	31
Şekil 4.20: Google Earth üzerinden alınan bir bina görseli. . . . .	32
Şekil 4.21: Alexnet ile ortak enformasyon bloğundan sonra elde edilen uydu ve kamera görüntüsü eşleşmesi. . . . .	32
Şekil 4.22: VGG16 ile ortak enformasyon bloğundan sonra elde edilen uydu ve kamera görüntüsü eşleşmesi. . . . .	33
Şekil 4.23: MobileNet ile ortak enformasyon bloğundan sonra elde edilen uydu ve kamera görüntüsü eşleşmesi. . . . .	34



## ÇİZELGE LİSTESİ

	<u>Sayfa</u>
Çizelge 2.1: Frekans bantları . . . . .	5
Çizelge 2.2: GPS, GLONASS ve GALILEO uydu özellikleri . . . . .	6





## KISALTMALAR

<b>GLONASS</b>	: Küresel Yörüngeli Seyrüsefer Uydu Sistemi (Global Orbiting Navigation Satellite System)
<b>GNSS</b>	: Küresel Uydu Seyrüsefer Sistemi (Global Navigation Satellite System)
<b>GPS</b>	: Küresel Konumlama Sistemi ( Global Positioning System)
<b>HOG</b>	: Rastgele Örnek Konsensüsü (Histogram of Gradients)
<b>IMU</b>	: Ataletsel Ölçü Birimi (Inertial Measurement Unit)
<b>INS</b>	: Ataletsel Seyrüsefer Sistemi (Inertial Navigation System)
<b>İHA</b>	: İnsansız Hava Aracı
<b>RANSAC</b>	: Rastgele Örnek Konsensüsü (Random Sample Consensus)
<b>SIFT</b>	: Ölçekten Bağımsız Öznitelik Transformasyonu (Scale-Invariant Feature Transformation)
<b>SLAM</b>	: Görsel Eşzamanlı Konum Belirleme ve Haritalama (Simultaneous Localization and Mapping)
<b>SURF</b>	: Hızlandırılmış Gürbüz Öznitelikler (Speeded-Up Robust Features)
<b>TERCOM</b>	: Arazi Kontur Eşleşmesi Seyrüsefer (Terrain Contour Matching)
<b>TRN</b>	: Arazi Görelî Seyrüsefer (Terrain Relative Navigation)
<b>VATAN</b>	: Viterbi Algoritması Arazi Destekli Seyrüsefer (Viterbi Algorithm Terrain Aided Navigation)

## 1. GİRİŞ

İnsansız hava araçlarının (İHA) enlem, boylam, yükseklik ve hız bilgisini ataletsel seyrüsefer sistemi (INS) ve küresel uydu seyrüsefer sistemi (GNSS) sağlar. GNSS kaybı olması durumunda, İHAlar konumlarını tam olarak tespit edememektedir. INS yaklaşık olarak İHA'ya konumunu bildirirse bile, GNSS kaybindan dolayı, INS doğrulama alamayacak, doğrulama alınamamasından ve sensörlerden gelen hata oranının gittikçe artmasından dolayı sürüklenme meydana gelecektir. Konumlama sistemindeki kayıp sebebi ile İHAlar güvenilir bir şekilde seyrüseferlerini devam ettirememektedir. Bu sebeple küresel uydu konumlama sistemi arızası sırasında seyrüsefere devam edilebilmesi için geliştirilen alternatif çözümler bulunmaktadır.

Yeryüzü şekillerinin haritaları kullanılarak, görüntü tabanlı seyrüsefer sırasında anlık haritalama işlemi yapıp konum tespit edilerek, ya da görüntü tabanlı öznitelik çıkarma algoritmaları kullanılırken haritalama yapılmadan INS biriken hataların çözümü ile uçuşa devam edilebilecek seyrüsefer sistemleri üzerinde çalışılmaktadır.

Bu tezde uydu görselleri ve hava aracı üzerine yerleştirilmiş faydalı yük kamerası ile görüntü tabanlı bir seyrüsefer sistemi ile İHAların seyrüseferlerine devam edebilmesi amaçlanmaktadır [1–6].

Bu bölümde GNSS olmayan ortamlarda seyrüsefere devam edilmesi için literatürde yer alan çalışmalardan bahsedilip, bu çalışmanın amacı ve motivasyonuna değinip, son olarak da tezin organizasyonu ile ilgili bilgi verilecektir.

### 1.1 Literatür Araştırması

İHAların en çok karşılaştığı GPS kaybı yaşanan ortamlarda seyrüseferine edememe sorunu ile ilgili pek çok yöntem araştırılmaktadır. Arazi modelleri, yeryüzü görüntüleri kullanılarak geliştirilen seyrüsefer sistemleri ve görüntü tabanlı geliştirilen seyrüsefer sistemleri bulunmaktadır. Görsel konum belirleme ve haritalama sistemi üç farklı aşamada incelenmektedir: haritasız sistem, harita tabanlı sistem ve harita oluşturma sistemi [1], [2].

Haritasız sistemlerde hava aracına önceden yüklenen bir harita olmadığı için hava aracı çevresindeki alanın özelliğini çıkartarak seyrüseferine devam etmeye çalışılmaktadır. Optik akış methodları ve öznitelik çıkarma haritasız görsel konum belirleme sisteminde en çok kullanılan methodlardır [1]. Yoğun optik akış hesaplamaları ile hareketli objelerin hareketleri de tespit edilebilmektedir [1], [7]. Optik akışın yanı sıra öznitelik çıkarma



metotları da hareket halindeki objelerin özniteliklerini çıkararak konum belirleme yapabilmektedir [1], [8].

GPS olmayan ortamlarda konum hesaplayabilmek ve alçak irtifa uçuşlarında uçuş bölgesindeki engellerden kaçınabilmek adına optik akış tahmin filtreleri ve Lidar tabanlı engel eşlemeden yararlanılmıştır [3]. İHA'nın hız bilgisini takip edebilmek adına optik akış ölçümleri kullanılmaktadır. Bu çalışma sırasında görüntünün yanı sıra IMU bilgileri de kullanılmaktadır. Hem görüntü hem de sensör bilgileri ile bu seysüsefer yönteminde genişletilmiş Kalman filtresi metodu uygulanıp, hem İHA'nın hem de takip edilen hedefin 3D konum ve hız bilgisi tahmin edilmektedir [3].

Harita tabanlı sistemlerde çevrenin önceden belirlenmiş haritası hava aracına verilmektedir [3]. TRN (Terrain Relative Navigation) seysüsefer sistemi arazi haritası ve aynı zamanda da irtifa bilgisini kullanarak geliştirilen seysüsefer yöntemidir. TERCOM (Terrain Contour Matching) ve VATAN (Viterbi Algorithm Terrain Aided Navigation) gibi çeşitleri bulunmaktadır [4].

Arazi seysüsefer yöntemi arazi modeline odaklanır. Bu yöntemde arazi modelinin yanısıra radar altimetre sensör bilgisi de kullanılmaktadır. Arazi seysüsefer modeli savaş uçağı gibi yüksek hıza sahip hava araçlarında kullanılmaktadır ve arazi yapısı düzlük olan ve engebelerin çok belirgin olmadığı bölgelerde ilgili yöntem kullanılamamaktadır. İrtifa değişikliği hassas yeryüzü eşleşmesi için uygun değildir bu yüzden de yavaş hıza sahip hava araçlarında bu yöntem kullanılmamaktadır [5].

Harita oluşturma sistemi görsel eş zamanlı konum belirleme ve haritalama (SLAM) teknikleri otonom sistemler üzerinde kullanılmaya başlanmıştır [1]. SLAM metodunda etrafın ön bilgisine ihtiyaç duyulmamaktadır. Mobil robotlar üzerindeki kamera ile senkron haritalama yapılabilmektedir. Kamera hava aracına yeryüzünü görebilecek şekilde takılıp, sisteme görsel bilgi sağlamaktadır. Bu görsel bilgiyi, özniteliklerini ve konumunu kullanıp, hava aracının konumunu hesaplamaya çalışmaktadır [6]. Bu yöntem eş zamanlı olarak harita oluşturabilmesine rağmen, derinlik bilgisi sağlayamamaktadır. Bu yöntem kullanılırken, hava aracının hangi bölgede ve nerede olduğunu bilmesi için kısa süreli GPS bilgisine ihtiyaç duyulmaktadır. Bu method başlangıç konumunu GPS bilgisi ile öğrendikten sonra, görsel bilgiyi kullanarak hava aracının konumunu hesaplamaya çalışmaktadır [6].

Seyrüsefere devam edilebilmesi için gerekli imge eşleştirme algoritmaları olarak hem ortak enformasyon hem de çapraz korelasyon (cross correlation) kullanılabilir. Çapraz korelasyon kullanılarak da ortak enformasyon gibi iki imge arasındaki ortaklıklar bulunabilmektedir. Hem çapraz korelasyonun hem de ortak enformasyonun kullanım alanlarına göre olumlu ve olumsuz yönleri bulunmaktadır [9]. Çapraz korelasyon da bu tez çalışmasında amaçlanan iki imge arasındaki benzerlikleri ölçmektedir, fakat

piksel yeğliliklerinden (intensity) etkilenmektedir. Bu da farklı zamanlarda çekilmiş, farklı hava şartlarında ve mevsimlerde alınmış imgelerin ortak özelliklerini çapraz korelasyonun piksel yeğlilik değerlerinden kaynaklı belirleyememektedir.

## 1.2 Tezin Amacı

Harita tabanlı, yeryüzü referanslı seyrüsefer sistemi üzerindeki çalışmalar, harita kullanılmadan optik akış ve öznitelik çıkarma algoritmaları kullanılarak geliştirilen alternatif seyrüsefer sistemleri ve anlık haritalama işlemi yapılarak geliştirilen görüntü tabanlı seyrüsefer sistemleri ile ilgili İHAlar için yapılan araştırmalar ve artan çalışmalar küresel konumlama sistemindeki anlık eksiklik veya kayıp durumunda İHAların seyrüseferlerine devam edememesinin önemini ortaya koymaktadır [1–6].

Tüm bu çalışmalarda karşılaşılan bazı zorluklar bulunmaktadır. Çalışmalarda yeryüzü referansı kullanılarak geliştirilen sistemlerde alçak irtifa da kullanılabileceği belirtilmiş [5] olup orta irtifa ve yüksek irtifa havada kalışlı sistemlerde bu yöntem kullanılamamaktadır. Optik akış methodlarının kullanıldığı [1] sisteminde de düşük irtifalı hava araçları için uygun olduğu ve geliştirildiği belirtilmiştir.

Bu tezde İHA üzerine yerleştirilmiş kameradan alınan görüntünün, önceden İHA'ya verilmiş etiketlenmiş uydu görüntüleri ile eşleştirilmesi yapıp, küresel konumlama sistemindeki veri kaybı sırasında da uydudaki konum bilgisinin İHA'ya verilerek seyrüseferin devam etmesi amaçlanmaktadır. Bu çalışma sırasında görüntülerin kamera ile yaklaştırılıp uzaklaştırılmasından kaynaklı ortaya çıkacak ölçek problemi sorun yaratmadığı için uygun bir faydalı yük kamerası ile düşük irtifa olmayan hava araçlarında da uygulanabileceği düşünülmektedir.

## 1.3 Tezin Organizasyonu

Bu tezde Bölüm 2'de GNSS sistemleri ve INS ile ilgili bilgi verilmektedir. Bölüm 3'te GPS kaybı yaşanan durumlarda kullanılabilecek konum belirleme yönteminin bahsedildiği görüntü işleme metotları ve sinir ağlarından oluşan algoritmaları içermektedir. Daha sonra, Bölüm 4'te hem sinir ağı algoritmasında çıkan varlık belirleme ve konum belirleme simülasyonları yer alırken, hem de genişletilmiş görüntü seti üzerinden uygulanan ortak enformasyon algoritmasından sonra hava aracının uydu görselleri ile eşleştirilmesinin simülasyon sonuçları sunulmaktadır. Son olarak, Bölüm 5'te sonuçlar verildikten sonra, gelecek çalışmalar için öneriler listelenmiştir.



## 2. GNSS SİSTEMLERİ VE INS

GNSS sistemleri Küresel Seyrüsefer ve Uydu Sistemi anlamına gelmektedir. GNSS sisteminde yeryüzünde bulunan alıcılar, uzaydan gönderilen dalgalarla birlikte bulunduğu konumun enlem, boylam, yükseklik bilgisini bulabilmektedirler.

Dünyada kullanılan ve farklı ülkelere ait GNSS sistemleri vardır. GPS, GLONASS, GALILEO bu sistemlerden bazılarıdır. GPS sistemi Amerika Birleşik Devletleri tarafından, GLONASS Rusya tarafından ve GALILEO Avrupa Birliği tarafından geliştirilmiş GNSS sistemleridir [10], [11].

Tüm GNSS uyduları yeryüzü üzerinde konum ve saatleri hassas olarak bilinen yer kontrol istasyonlarından izlenmektedirler. Bu istasyonlar uydu yörünge düzeltmelerinin hesaplanması ve saat hatalarının giderilmesinde rol almaktadır.

GPS ve GLONASS uyduları L frekans bantlarında, GALILEO ise E frekans bantlarında sinyal yayınlarlar [12], [13]. GNSS sistemleri ve yayın yaptığı frekansları Çizelge 2.1'de belirtilmiştir:

Çizelge 2.1: Frekans bantları [12].

Sistem	Sinyal	Frekans(MHz)
GPS	L1 C/A	1575.42
	L2 C	1227.60
	L2 P	1227.60
	L5	1176.45
GLONASS	L1 C/A	1598.06-1609.31
	L2 C	1242.93-1251.68
	L2 P	1242.93-1251.68
	L3 OC	1202.02
GALILEO	E1	1275.42
	E5a	1176.45
	E5b	1207.14
	E5 AltBOC	1191.79
	E6	1278.75

Yerde bulunan alıcının konumunu belirleyebilmesi için dört uydudan sinyal yayını alması gerekmektedir [10]. Alıcı sinyal aldığı uyduların konumunu bildiği için, kendi

bulunduğu konumu hesaplarırken sinyalin yayınlanması ve alıcıya gelişi arasındaki zaman farkını kullanmaktadır. Dört uydudan gelen bilgi ile enlem, boylam, yükseklik ve saat bilgisi de elde edilmektedir [10].

GPS, GLONASS ve GALILEO her biri için kullanılan uydu sayısı, yörünge yarıçapı ve derecesi Çizelge 2.2’de belirtilmiştir:

Çizelge 2.2: GPS, GLONASS ve GALILEO uydu özellikleri [14].

	<b>GPS</b>	<b>GLONASS</b>	<b>GALILEO</b>
<b>Uydu</b>	27 + 4	24 + 3	27 + 3
<b>Yörünge Düzlemi</b>	6	3	3
<b>Yörünge Eğimi</b>	55 derece	64.8 derece	56 derece
<b>Yörünge Yarıçapı</b>	20,200 km	19,140 km	23,222 km

## 2.1 GPS

GPS için kullanılan temel seyrüsefer tekniği, tahmini konumlarını da yayınlayan GPS uydularının tek yönlü kullanımınıdır [10]. ABD Hava Kuvvetleri ve Donanması 1972’de sürdürdüğü çalışmasında uzaydan kontrol edilebilen bir seyrüsefer sistemi incelemelerinde bulunmuş ve günümüz NAVSTAR veya GPS olarak da bilinen sistemin temelleri atılmıştır [10]. 1978’de ilk Block-I GPS uydusu fırlatılmıştır [15]. 2005 yılında ilk modernize edilmiş GPS uydusu piyasaya sürülmüştür. Bu modernize çalışması yerdeki alıcılara daha fazla sinyal gücü sağlayacak bir anten ve kullanıcı için ikinci bir sivil sinyal içermektedir [16].

GPS 27 uydudan oluşan ve küresel kapsama alanı sağlayan bir sistemdir [17].

## 2.2 Glonass

Rusya tarafından geliştirilen küresel uydu seyrüsefer sistemidir. Seyrüsefer için uyduları kullanmanın ilk önerisi 1957 yılında V. S. Shebashevic tarafından yapılmıştır. Yapılan araştırmalar sonucunda 1963 yılında Ar-Ge projesi olarak Sovyet düşük yörüngeli "Cicada" sistemi kullanılmıştır. 1967 yılında ilk Sovyet seyrüsefer uydusu "Cosmos-192" üretilmiştir. 4 uydunun "Cicada" sistemi 1979 yılında hizmete girdi ve seyrüsefer uyduları 83 derecelik bir eğim ile 1000 km yüksekliğinde dairesel yörüngelere yerleştirilmiştir. Bu sistemde yaklaşık her 2 saatte bir uydulardan birini alıp, 5-6 dakika içerisinde pozisyonun düzeltilmesi sağlanmaktadır. Bu sistemle birlikte günümüzde kullanılan GLONASS sisteminin temelleri atılmıştır [11].

GLONASS adı verilen Rus yüksek yörünge uygu navigasyon sisteminin uçuş testleri 1982’de Kosmos-1412 uydusu ile başlayıp, 1993 yılında resmi olarak faaliyete geçmiştir

[11].

GLONASS [11] 24 uydudan oluşan küresel kapsama alanı sağlayan bir sistemdir [17].

### 2.3 Galileo

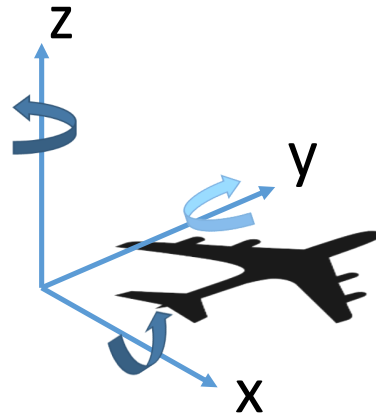
Avrupa tarafından geliştirilen küresel uydu seyrüsefer sistemidir. Avrupa GALILEO için ilk iki uydusunu 2011’de fırlatılmıştır. 2014’te Kourou Avrupa uzay limanında GALILEO’nun tam operasyonel yetenek uyduları fırlatıldı, fakat yörünge enjeksiyonu planlandığı gibi ilerleyemediği için yörünge konumlarına ulaşamamıştır. 2015’te Avrupa Birliği 7 ve 8 numaralı tam operasyonel yetenek uyduları fırlatılmış ve başarılı olmuştur. 2018’de 4 GALILEO uydusunun (Samuel, Anna, Ellen ve Patrick) Kourou Avrupa uzay limanından kalkışı gerçekleşti ve yörüngedeki beklenen konumları teyit edilmiştir. Sistemin 30 uydu ile hizmet vermesi planlanmaktadır [18].

### 2.4 INS

INS sistemi ataletsel seyrüsefer sistemidir ve bu sistemin yeryüzündeki ya da uzaydaki bir istasyonla haberleşmesine gerek olmadan, uçuş sırasında hava aracının yerinin ve konumunun tespitinde kullanılmaktadır.

IMU ataletsel ölçüm birliğidir ve entegre bir sensör paketidir. Kuvvet ve açısal hızın üç boyutlu ölçümü için birleştirilmiş ivme ölçer ve cayrolardan oluşmaktadır. 3 ortogonal eksen üzerine dizilmiş 6 sensörden oluşmaktadır. 3 eksenin her birisinde bir ivme ölçer ve bir cayro bulunmaktadır [19]. IMU tek başına konum, hız gibi seyrüsefer bilgilerini vermemektedir [20].

IMU’dan gelen sensör bilgilerini kullanarak, INS sistemi bir nesnenin başlangıç noktasına, yönüne ve hızına göre konum, hız, yön gibi seyrüsefer bilgilerini sağlamaktadır [20] ve ilgili yönler Şekil 2.1’de gösterilmiştir.



Şekil 2.1: Hava aracı dönüş eksenleri [19].

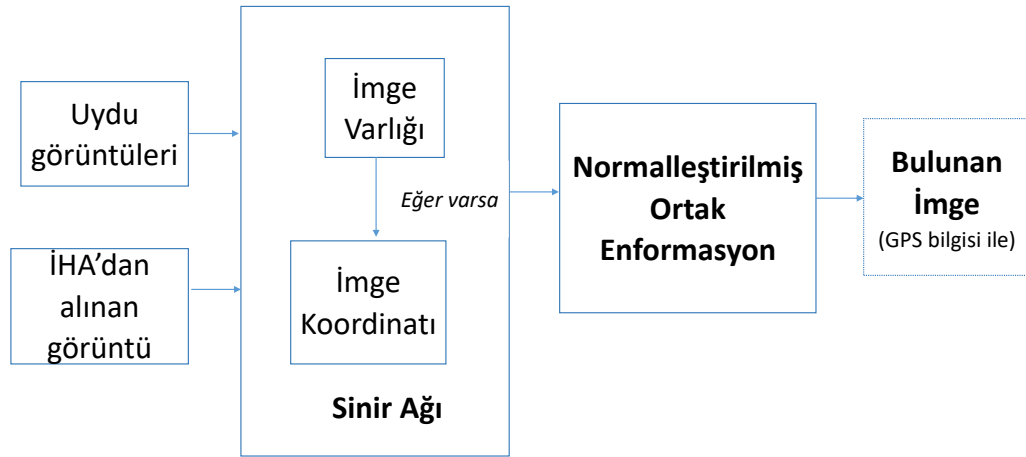


### 3. GPS KAYBI YAŞANAN ORTAMLARDA KONUM BELİRLEME YÖNTEMİ

Bu bölümde öncelikli olarak çalışmada kullanılan evrişimsel sinir ağı ile çıkartılan özellikler ve tasarlanan tam bağlı sinir ağlarından oluşan iki farklı sinir ağı ile görüntülerin var olup olmadığının tespiti ve İHA üzerine yerleştirilmiş kameradan gelen görüntü içinde ilgili alanın yerinin tespiti anlatılacaktır. İki görüntü arasında hesaplanan normalize edilmiş ortak enformasyon bilgisi üzerine sinir ağından gelen bilgi dahil edilerek görüntülerin eşleştirilmesi anlatılacaktır.

Daha sonra, küresel konumlama bilgisi eksikliğinde ataletsel sistemlerdeki hatanın artmasından kaynaklı daha geniş bir alanda arama işlemi gerekeceğinden dolayı, İHA'dan gelen görüntünün daha geniş olarak nasıl birleştirildiğinden bahsedilmektedir. Daha sonra, önerilen metot için seçilen veri seti ve seri setindeki etiketleme işlemi anlatılacaktır. Tüm bu işlemler için kullanılan teknikler, yöntemler, metotlar ile ilgili bilgi bu başlık altında sırası ile verilecektir.

Şekil 3.1'de gösterildiği gibi algoritmanın genel mimarisinde Sinir Ağı bloğu ve Normalleştirilmiş Ortak Enformasyon bloğu olmak üzere iki temel blok bulunmaktadır.



Şekil 3.1: Algoritmanın genel mimarisini.

Çalışma sırasında kullanılan uydu görüntülerinden oluşan ve hava aracı kamerasından alınan görüntülerden oluşan iki ayrı görüntü seti bulunmaktadır. Sinir ağı bloğunda uydudan görünen objenin, kameradan alınan görsel içinde olup olmadığını anlayan imge varlığı tespit bloğu ve eğer objenin varlığı, hava aracı kamerasından tespit edilebiliyorsa, kamera görseli üzerindeki koordinatlarının tespiti yapılmaktadır. Sinir ağı blok çıktısı



görüntülerin yaklaşık olarak eşleşmesini sağladıktan sonra, Normalleştirilmiş Ortak Eformasyon Bloğunda ortak sinir ağı blok sonucuna belirli bir ağırlık verilerek görüntülerin normalleştirilmiş ortak enformasyonu hesaplanmaktadır. Ortak enformasyonun maksimum olduğu bölge, bulunup, kamera görüntüsünde uydu görüntüsünden eşleştirilen objenin konumu hava aracına sağlanmaktadır. Bu çalışma sırasında irtifa bilgisi elde edilmemektedir.

### 3.1 Sinir Ağına Dayalı Seyrüsefer Sistemi

İHA'ların uçuş gerçekleştirdiği ortamlar oldukça çeşitlilik gösterebilmekte ve bununla birlikte ortaya çıkan olası tespit edilmesi gereken objeler de ayrışmaktadır. Bu nedenle çok çeşitli obje kümesi üzerinde sağlıklı modelleme yapabilecek bir sistem gerekmektedir. Sinir ağları, yüksek modelleme kapasiteleri ve değişken durumlara adapte olabilme yeteneklerinden ötürü bu çalışmada öznitelik çıkarma modeli olarak tercih edilmiştir.

Tasarlanılan İHA Seyrüsefer Destek Sistemi kapsamında kameralardan alınan görüntüler ilk olarak sinir ağı alt sistemi tarafından işlenmektedir. Bu sinir ağı alt sistemi *i*) Sinir Ağı Tabanlı Öznitelik Çıkarma Modülü *ii*) Sinir Ağı Tabanlı Objeye Tespit Modülü ve *iii*) Sinir Ağı Tabanlı İmge Çakıştırma Modülü olmak üzere üç modülden oluşmaktadır.

#### 3.1.1 Sinir ağı tabanlı öznitelik çıkarma modülü

Bu bölümde, evrimsel sinir ağı tabanlı öznitelik çıkarma modülü anlatılmaktadır. İHA'ların karşılaşılabileceği objelerin renk, boyut, desen gibi öznitelikleri çok çeşitli olabileceği için tüm öznitelikleri modelleme kapasitesine sahip olan sinir ağlarından faydalanılmıştır. Özellikle, evrimsel sinir ağları, tüm sinir ağları içerisinde mekansal bilgiyi daha iyi kullanan ve üstün performans gösteren bir sinir ağı çeşididir [21]. Bu nedenle, öznitelik çıkarma işleminde evrimsel sinir ağlarından faydalanılmıştır.

Öznitelik çıkarma modülü temel olarak çok katmanlı bir evrimsel sinir ağı olmakla beraber şu şekilde çalışmaktadır. Şekil 3.2'de görüldüğü üzere, İHA'dan  $t$  anında alınan görüntü,  $I_t^{IHA}$ , bu modülden geçirilerek çok boyutlu uzayda  $I_t^{IHA}$ 'ı temsil eden öznitelikler çıkartılır. Bu öznitelikler  $Z_t^{IHA}$  ile gösterilmektedir.

$$Z_t^{IHA} = CNN_{FE}(I_t^{IHA}) \quad (3.1)$$

Burada,  $CNN_{FE}$  öznitelik çıkaran evrimsel sinir ağını temsil etmektedir. Bununla birlikte daha önceden elde edilmiş konumları bilinen uydu görüntüleri  $I_i^{Uydu}$  da bu sinir

ağından geçirilerek  $Z_i^{Uydu}$  öznitelikleri elde edilir:

$$Z_i^{Uydu} = CNN_{FE}(I_i^{Uydu}) \quad (3.2)$$

Burada, İHA görüntüleri zaman  $t$  ile indekslenmesine karşın, uydu görüntüleri dizin  $i$  ile indexlenmiştir. Bunun nedeni uydu görüntüleri anlık olarak alınmamakta, önceden toplu olarak alınmaktadır. Bu durum, uydu resimlerinin uçuş esnasında öznitelik çıkarma modülünden tekrar geçirilme gereksinimini ortadan kaldırmaktadır. Bu durumda,  $t$  anında uydudan alınan görüntüyü öznitelik çıkarma modülünden geçirdikten sonra elde edilen  $Z_i^{IHA}$  ile önceden elde edilmiş  $Z_i^{Uydu}$  lar ile işleme devam edilebilmektedir. Bu kısımdan sonra elde edilen  $Z_i^{IHA}$  ve  $Z_i^{Uydu}$  obje tespit modülüne gönderilmektedir. Öznitelik çıkarma amacı ile kullanılan sinir ağları aşağıda anlatılmaktadır.

- **Alexnet** [22], 2012 yılında ImageNet veri kümesi üzerinde yapılan "ImageNet Large Scale Visual Recognition Competition" (ILSVRC) yarışmasının kazananı olan sinir ağı mimarisidir. Alexnet, bu yarışmada %15.3 en-iyi-5 hata oranı performansına ulaşarak birinci olmuştur. Alexnet mimarisinin ikinci olan algoritmaya yaklaşık uzaklığı %10.8 en-iyi-5 hata oranıdır. Alexnet mimarisinin yakaladığı bu başarı, kullandığı derin sinir ağı mimarisine olan ilgiyi arttırmış ve bilgisayarlı görü alanında bir sıçrama yaratmıştır.

Alexnet mimarisi beş adet evrimsel sinir ağı katmanı ve bunların ardından üç adet tam bağlantılı sinir ağından oluşmaktadır. Burada, evrimsel ve tam bağlantılı sinir ağları, öznitelik çıkarma ve sınıflandırma modülleri olarak ayrışmaktadır. Bu çalışmada, Alexnet tabanlı öznitelik çıkarma modülünde beş adet evrimsel sinir ağı katmanı kullanılmıştır. Evrimsel sinir ağı katmanları arasında en-çok-ortaklama (max-pooling), düzenlenmiş doğrusal ünite (rectified linear unit (ReLU)) modülleri bulunmaktadır. ReLU aktivasyon fonksiyonu ilk olarak bu makalede tanımlanmıştır. Ayrıca, bu mimaride yerel karşılık normalizasyonundan (local response normalization) yararlanılmıştır:

$$\hat{a}_{x,y} = \frac{a_{x,y}}{\left(\varepsilon + \alpha \sum_{j=0}^{N-1} (a_{x,y}^j)^2\right)^\beta}$$

Burada,  $a_{x,y}$ ,  $(x,y)$  koordinatında bulunan pikselin değerini,  $\hat{a}_{x,y}$  ise bu piksele karşılık gelen normalize edilmiş piksel değerini temsil etmektedir.  $\varepsilon$ ,  $\alpha$ ,  $\beta$  ve  $N$  ise yerel karşılık normalizasyon işleminin parametrelerini belirtmektedir.

- **VGG** [23] sinir ağı 2014 ILSVRC yarışmasında ikinci olmuştur. Aynı yarışmanın lokalizasyon kategorisinde ise birinci olmuştur. Evrimsel sinir ağlarında,

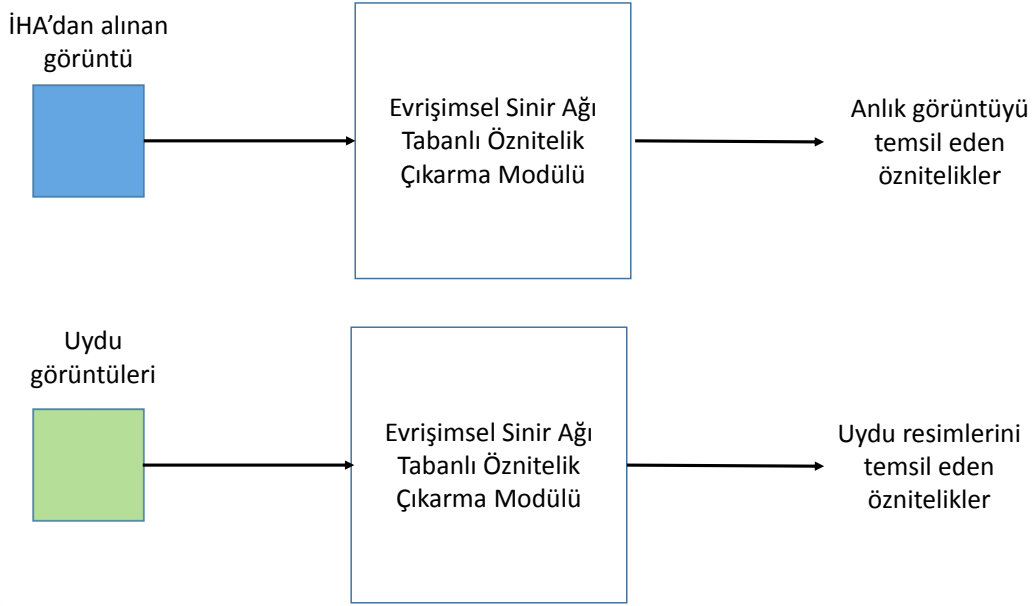
kullanılan filtrelerin boyutları da farklı değerler kullanılarak en iyilenebilir. Örneğin, Alexnet farklı katmanlarda  $(11 \times 11)$ ,  $(5 \times 5)$  ve  $(3 \times 3)$  boyutlarında filtreler kullanmaktadır. VGG mimarisi ise filtre boyutunu  $(3 \times 3)$  olarak belirlemiş kalan en iyilemeleri bu filtreler üzerinden yapmıştır. Bu çalışmada, farklı derinlikte ve farklı değişkenlerle versiyonları olan VGG sinir ağının, on üçü evrişimsel, üçü tam bağlantılı sinir ağı olmak üzere toplam on altı katmandan oluşan ve dizi normalizasyonundan yararlanan versiyonu ele alınmıştır. Bu çalışmada, VGG16 tabanlı öznetelik çıkarma modülünde on üç adet evrişimsel sinir ağı katmanı kullanılmıştır.

- **MobileNet** [24] sinir ağı evrişim operasyonlarından gelen yüksek hesaplama yükünü azaltmak amacıyla ortaya konmuş bir mimaridir. Klasik evrişim operasyonu yerine derinliksel ayrılabilen evrişim işlemi denilen bir yapı kullanır. Bu yapıda,  $(3,3)$   $(1,1)$  boyutundaki filtrelerle birlikte toplu normalizasyon (batch-normalization) ve ReLU6 aktivasyon fonksiyonları bulunmaktadır. [24] çalışmasında, öznetelik çıkarma modülü olarak bu yapıdan on dokuz tanesi kullanılmıştır.

### 3.1.2 Sinir ağı tabanlı obje tespit modülü

Obje tespit modülünün amacı, İHA'dan  $t$  anında alınan görüntü  $I_t^{IHA}$  içerisinde, belirli objelerin var olup olmadığını saptamaktır. Uydu setindeki obje sayısının yüksek olduğu durumlarda, İHA'nın son bilinen uçuş konumuna uzaklığı belirli bir üst sınırın içerisinde kalan objeler aday olarak seçilip işleme bu objelerin uydu fotoğraflarıyla devam edilebilir.  $I_j^{Uydu}$ , bu şartı sağlayan objelerin uydu görüntülerini ifade etmektedir. Sinir ağı tabanlı obje tespit modülü, İHA'dan alınan anlık görüntü ve belirli objelerin uydu görüntülerinin bir önceki adımda öznetelik çıkarma modülü tarafından çıkarılmış öznetelikleri olan  $Z_t^{IHA}$  ve  $Z_j^{Uydu}$ , yi girdi olarak almaktadır. Temel olarak bir ikili sınıflandırıcı (binary classifier) olan obje tespit modülü,  $Z_t^{IHA}$  ve  $Z_j^{Uydu}$ , yi işleyerek,  $I_j^{Uydu}$  görüntüsünün ait olduğu objenin  $I_t^{IHA}$  içerisinde var olup olmadığına karar vermektedir.

Burada, yalnızca  $I_t^{IHA}$  veya  $Z_t^{IHA}$  üzerinden çoklu obje tespiti yaklaşımında işlem yapılmamasının sebebi karşılaşılabilecek objelerin sınıflarının/sınıf sayısının sınırlandırılmak istenmemesidir. Bu çalışmada, önceden belirlenmiş sınıflara ait objeleri tespit etme yaklaşımı yerine, jenerik olarak, görüntüsü verilmiş herhangi bir objenin tespiti yaklaşımı takip edilmektedir. İlgili süreç Şekil 3.2'de gösterilmektedir.



Şekil 3.2: Öznitelik çıkarma işlemi.

### 3.1.3 Sinir ağı tabanlı imge çakıştırma modülü

İmge çakıştırma modülünün amacı, varlığı bir önceki adımda obje tespit modülü tarafından belirlenmiş olan bir objenin uydu görüntüsünün,  $I_j^{Uydu}$ , İHA görüntüsü  $I_t^{İHA}$  içerisindeki konumunu saptamaktır. Bu işlem, daha önceki adımda, öznitelik çıkarma modülü tarafından belirlenmiş öznitelikler olan  $Z_t^{İHA}$  ve  $Z_j^{Uydu}$  kullanılarak yapılmaktadır.

İmge çakıştırma modülü, tespit edilen objenin  $I_t^{İHA}$  içerisindeki sınırlarını belirleyen  $(x_{max}, y_{max}, x_{min}, y_{min})$  bilgilerini çıktı olarak dönmektedir.

## 3.2 İmge Birleştirme

Hava araçlarında küresel konumlama bilgisinde sorun olduğu durumlarda, ataletsel seyrüsefer sistemi de sürüklenmeden kaynaklı hata artışı olmaktadır. İdeal durumda sürüklenme gibi bir sorun olmasa, ataletsel seyrüsefer sistemi ile hava aracı matematisel olarak hesaplanabilen uçuş rotasında seyrüseferine devam edebilecektir, fakat sürüklenmeden kaynaklı olarak, hava aracı olması gerektiği rotadan sapabilmektedir. Görüntüleri eşleştirebilmek için bu sürüklenme durumundan dolayı daha geniş bir alanda arama yapılması gerekmektedir. Bu problem için GPS kaybında, daha geniş bir alanda bakılarak ortak enformasyon hesaplanması gerekmektedir. Ortak enformasyon hesabından önce alanın genişletilmesi için görüntü birleştirme tekniği kullanılmıştır. Küresel konum eksikliği ikazı alındığında, kameradan gelen imgeler, bir sonraki imge ile birleştirilip, daha geniş bir görsel elde edilecektir. Bu geniş imgeler üzerinde de

uydudan gelen görseller ile birlikte ortak enformasyon hesabı yapılmaktadır. Görüntü birleştirmeden önce, daha küçük bir alanda uydu görselleri eşleştirilmeye çalışılırken, görüntülerin görüş alanının genişletilmesi, görüş alanına giren objeleri artıracığından dolayı, uydudan gelen görseller ile eşleşme oranını arttıracaktır.

İmge birleştirme imgeler arasındaki uygunluğu bulma, imgeler arasındaki olası hareket kümesini tespit etme, imgeler arasındaki hizalama ve imgeler arası birleştirme olmak üzerinde dört aşamada incelenebilir [25].

Görüntüler arası uygunluk hesaplanırken, öznitelik algılama, ardından algılanan her bir öznitelik için öznitelik betimleme ve en son olarak da öznitelik eşleştirme yapılmaktadır [25].

İmgeler arası olası hareket kümesi hesaplanırken, yüksek modelleme kapasitesine sahip olan homography tercih edilmiştir ve  $H$  matrisi ile ifade edilmektedir [25].

$$\begin{bmatrix} h_{00} & h_{01} & h_{02} \\ h_{10} & h_{11} & h_{12} \\ h_{20} & h_{21} & 1 \end{bmatrix} \quad (3.3)$$

Aynı görüntünün iki farklı açıdan çekilen görüntülerinde 1. imgedeki  $(x_0, y_0)$  noktası, 2. imgedeki  $(x_1, y_1)$  noktasına karşılık gelmektedir. Kartezyan koordinatı içinde hareket kümesi (3.4) ve (3.5) gösterilmiştir[25]:

$$x_1 = \frac{h_{00}x_0 + h_{01}y_0 + h_{02}}{h_{20}x_0 + h_{21}y_0 + 1} \quad (3.4)$$

$$y_1 = \frac{h_{10}x_0 + h_{11}y_0 + h_{12}}{h_{20}x_0 + h_{21}y_0 + 1} \quad (3.5)$$

Burada,  $H$  matrisinin parametrelerinin çözümü için temel olarak bir doğrusal olmayan en az kareli hata (non-linear least square) problemi çözülmektedir. İmgeler arasındaki hizalama için RANSAC kullanılıp, en iyi eşleşmeler rastgele olarak alınmaktadır ve bunlar üzerinden eşleşmeler yapılmaktadır. Hizalamadan sonra son olarak görüntülerin birleştirilmesi, harmanlanması (blending) yapılmaktadır [25]. Alfa blending görüntülerin ortalamasını alarak yapılan bir harmanlama yöntemidir, bu çalışmada imgelerin birleştirilmesi sırasında alfa blending kullanılmıştır. Bu işlemler için OpenCV [26] kütüphanesi kullanılmaktadır.

### 3.3 Ortak Enformasyon

Bu bölümde ortak enformasyonun tarihçesinden, tanımından, ve bu araştırma sırasında sinir ağı bloğundan çıkan sonuçlar kullanılarak uydu ve hava aracı görüntüleri arasında benzerlik eşleştirilmesi sırasında nasıl kullanıldığından bahsedilecektir.

#### 3.3.1 Ortak enformasyon tarihçesi

Ortak enformasyon, benzer görüntüleri bulma varsayımı ile [27], [28] tarafından 1990ların başında ilk olarak imge çakıştırma olarak tanıtılmıştır. Bir imge içerisindeki benzer gri değerlerinin, diğer imge içerisinde de karşılıklarını aramaktadır. [29] ise bağlantı histogramını bulmuş ve iki imgede de karşılıklı gelen tüm noktalar için gri değerlerin kombinasyonlarını geliştirmişlerdir.

#### 3.3.2 Ortak enformasyon tanımı

Ortak enformasyon sinyallerin entropisi kullanılarak hesaplanmaktadır. Entropi genel olarak enformasyon ölçüsü olarak adlandırılmaktadır [30]. Entropi sistem bozukluğunu ölçmektedir. Eğer sistemdeki çıktı dağılımı düşük ise, sistemin belirli çıktılar verdiği ve çok dağınık bir çıktı havuzu olmadığı anlamına gelir, bu durum da sistemin entropisi düşüktür. Eğer sistemin çıktı dağılımı fazla ise, yani sistemin bozukluğu fazla ise, entropisi de yüksektir. Shannon her bir sonuç için olan enformasyon bilgisini, o sonucun görünme olasılığı olarak tanımlamaktadır. İmge çakıştırma çalışmalarında genellikle Shannon entropy kullanılmaktadır [31], [32], [33].

Değişkenin entropisi, o değişkenin içerdiği bilgi anlamına gelmektedir.  $X$  ve  $Y$  rasgele değişkenin bağlantı olasılık dağılımı  $p_{xy}(x,y)$  ile,  $X$  rasgele değişkeninin olasılık dağılımı  $p_x(x)$  ile ve  $Y$  rasgele değişkeninin de olasılık dağılımı da  $p_y(y)$  ile gösterilmektedir.  $p_{xy}(x,y)$ ,  $p_x(x)$  ve  $p_y(y)$  arasındaki bağlantı (3.6) ve (3.7) ile ifade edilir.

$$P_X(x) = \sum_y P_{XY}(x,y) \quad (3.6)$$

$$P_Y(y) = \sum_x P_{XY}(x,y) \quad (3.7)$$

$X$  rasgele değişkeninin Shannon entropisi  $H(X)$  ile gösterilir ve (3.8) ile ifade edilir.

$$H(X) = - \sum_{i=1}^n p_i \log(p_i) \quad (3.8)$$

$$H(Y) = - \sum_{j=1}^m p_j \log(p_j) \quad (3.9)$$

Burada,  $-\log(p_i)$  yani  $\log(1/p_i)$  pi olasılıklı bir olayın tersinden elde edilen enformasyon miktarını göstermektedir. Entropi de olaylar topluluğundan elde edilecek enformasyonların ortalamasıdır [33].

Gri değerlerin bağlantı olasılık dağılımını bulmak için iki farklı resmin bağlantı histogramı (joint histogtam) kullanılmaktadır [33].  $X$  ve  $Y$  rasgele değişkeninin bağlantı olasılık dağılımının Shannon entropisi  $H(X,Y)$  ile gösterilir ve (3.10) ile ifade edilir.

$$H(X,Y) = - \sum_{i=1}^n \sum_{j=1}^m p_{ij} \log(p_{ij}) \quad (3.10)$$

Ortak enformasyon bir çok şekilde ifade edilebilir. İlk olarak imgelerin ikisinin de entropisi kullanılırken, aynı zamanda imgelerin bağlantılı entropisi de kullanılmaktadır. Bağlantılı entropinin kullanıldığı ortak enformasyon denklemi aşağıdaki gibi ifade edilmektedir.

$$MI(X,Y) = H(X) + H(Y) - H(X,Y) \quad (3.11)$$

Burada,  $H(X)$ ,  $X$  rasgele değişkeninin Shannon entropisini,  $H(Y)$  de  $Y$  rasgele değişkeninin Shannon entropisini gösterirken,  $H(X,Y)$  ise  $X$  ve  $Y$  rasgele değişkenlerinin bağlantılı entropisini göstermektedir. Bu formül ile bağlantılı entropiyi azaltırken, ortak enformasyon artırılmaktadır [33].

Ortak enformasyonun bir diğer gösterim şekli de şartlı entropinin kullanılmasıdır. Şartlı entropi  $H(X|Y)$  ile gösterilirken,  $X$  imgesi içinde koşullu olasılıktaki  $i$ 'de gri değer değişimini göstermektedir. Görüntülerden bir tanesinin entropisi ve iki görüntünün şartlı entropisi kullanılarak hesaplanan ortak enformasyon denklemi ve koşullu entropi denklemi aşağıdaki şekilde ifade edilmektedir.

$$H(X|Y) = - \sum_{i=1}^n \sum_{j=1}^m p_{ij} \log(p_{ij}) \quad (3.12)$$

$$H(Y|X) = - \sum_{i=1}^n \sum_{j=1}^m p_{ij} \log(p_{ji}) \quad (3.13)$$

$$MI(X, Y) = H(X) - H(X|Y) = H(Y) - H(Y|X) \quad (3.14)$$

$H(X)$ ,  $X$  rasgele değişkenin,  $H(Y)$ ,  $Y$  rasgele değişkenin Shannon entropisini gösterirken,  $H(X|Y)$  ve  $H(Y|X)$ 'de koşullu entropiyi ifade etmektedir.

Ortak enformasyon (3.13) ve (3.9) denklemleri kullanılarak aşağıdaki şekilde hesaplanmaktadır.

$$MI(X, Y) = H(Y) - H(Y|X) = - \sum_{j=1}^m p_j \log(p_j) + \sum_{i=1}^n \sum_{j=1}^m p_{ij} \log(p_{ji}) \quad (3.15)$$

Bayes teoremi kullanılarak ( $p_{ij} = p_i p_{j|i} = p_j p_{i|j}$ ), ortak enformasyon aşağıdaki şekilde hesaplanmaktadır.

$$MI(X, Y) = \sum_{i=1}^n \sum_{j=1}^m p_{ij} \log\left(\frac{p_{ij}}{p_i p_j}\right) \quad (3.16)$$

### 3.3.3 Ortak enformasyon ile seyrüsefer sistemi

Ortak enformasyon, "Ortak Enformasyon Tanımı" bölümünde de belirtildiği gibi hem uydudan gelen objelerin olduğu imgeleri hem de İHA kamerasından gelen imgelerin ortak özneliklerinin maksimum olduğu bölgenin bulunmasını sağlamaktadır. Ortak enformasyon uygulanmadan önce ölçeklendirme problemi, yakın ortak enformasyon dağılımı olan bölgelerde yanlış alanı belirleme gibi çözülmesi gereken problemler bulunmaktadır.

Farklı iki kaynaktan gelen imgeler olduğu için ölçeklendirme problemi ile karşılaşılmaktadır. Hem uydudan gelen imgede görülen objenin boyutları hem de aynı objenin hava aracı üzerindeki kamera ile alınan boyutları birbirinden farklı olduğu için bu ölçeklendirmeyi eşitlemek gerekmektedir. Bunun için de sinir ağlarından gelen çıktılar kullanılmaktadır. Sinir ağından gelen çıktı içerisinde İHA'dan gelen görüntü üzerindeki tahmin edilen uydudan gelen objenin boyutları bulunmaktadır. Ortak



enformasyonu kullanmadan önce, uydudan gelen görsele, tahmin edilen obje boyutunda olabilmesi için yeniden boyutlandırma işlemi yapılmaktadır.

Ortak enformasyon hesaplanmadan önce, sinir ağı çıktı olarak İHA kamera görüntüsü üzerinde uydu görselinden gelen objenin olduğu bölgenin boyutlarını vermektedir. Bu bilgi de sadece ölçeklendirme problemi için değil, aynı zamanda da daha geniş alan içerisinde ortak enformasyon hesaplaması sırasında da kullanılmaktadır. Bu işlem ile ortak enformasyonun hesabı sırasında, dağılımın yakın olduğu bölgelerde yanlış bölgenin işaretlenmesini engellemektedir.

### **3.4 Veri Seti**

Çalışma sırasında oluşturulan iki farklı görüntü veri seti bulunmaktadır, bu bölümde kullanılan veri setinden bahsedilecektir.

#### **3.4.1 Uydudan alınan veri seti**

Hava aracı kamerası ile alınan görüntülerin eşleştirilmesi için gerekli uydu görüntüleri Google Maps üzerinden alınmıştır. Dron ile çekim yapılan bölge Google Maps üzerinden bulunarak, İHA kamerası içerisinde görülen objeler, uydu görüntüsü içerisinde alınarak bir veri seti oluşturulmuştur. Kamera görüş alanına giren her bir obje, eğer uydu üzerinde karşılığı varsa, Google Maps üzerinden uydu görüntü setine veri olarak alınmıştır.

#### **3.4.2 İHA'dan alınan veri seti**

Bu araştırmanın İHA'lar üzerinde kullanılabilmesi için hava aracına yeryüzünü görecektir şekilde takılı olan faydalı yük kamerası bulunmalıdır. Bu araştırma boyunca [34]'ten alınan görüntü seti kullanılmıştır. Bu görüntü seti Amerika'da Cedaredge, Colorado bölgesinde bir yerleşim yerinden alınmıştır. Kullanılan görseller İHA'dan alınmış olup, 82 adet görüntü içeren küçük bir veri setidir. Bu veri seti ile sinir ağını eğitebilmek için etiketleme işlemleri yapılmıştır. Etiketleme işlemi İHA'dan gelen görseller üzerinde yapılmaktadır. Hava aracı kamerasından gelen görüntüler içerisinde bina gibi belirli objeler varsa ve uydu görüntüleri üzerinde de bu objeler bulunuyorsa, bu objeler İHA görüntüleri üzerinde işaretlenmektedir. İşaretleme sırasında ana görüntü üzerinde işaretlenen objelerin konumları ana görüntünün yatay ve dikey referansı ile  $x_{min}$ ,  $y_{min}$ ,  $x_{max}$  ve  $y_{max}$  olarak belirlenmektedir. Bu işaretleme işlemi sonuçları *.txt* ve *.xml* uzantılı dosyalar olarak kaydedilmiştir.

## 4. SİMÜLASYON ORTAMI VE SONUÇLARIN ANALİZİ

Üç farklı ağ kullanılarak hem kameradan gelen görüntü hem de uydudan gelen görüntü için öznelikler tespit edilmektedir. Sırasıyla Alexnet, VGG ve MobileNet öznelik çıkarmaları kullanılarak elde edilen sonuçlar bu başlık altında sunulacaktır.

### 4.1 Sinir Ağı Eşleşme Sonuçları

Alexnet, VGG ve MobileNet ile çıkartılan özneliklerden sonra kamera görüntüsü üzerinde uydu objesinin eşleştirilmesi, koordinatlarının gösterilmesi ve hata oranlarının bulunması ile ilgili sonuçlar burada sunulacaktır.

#### 4.1.1 Alexnet kullanılan sinir ağı eşleşmesi

Alexnet ile çıkartılan özneliklerden sonra kamera görüntüsü üzerinde uydu objesinin eşleştirilmesi ve koordinatlarının gösterilmesi için iterasyon-hata oranı ve iterasyon-kesişim kümeleri (Intersection of Union, IoU) grafikleri Şekil 4.1, Şekil 4.2, Şekil 4.3 ve Şekil 4.4'de verilmiştir.

Modelin, imge birleştirme işlemi gerçekleşmeden önce elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki obje tespit oranı %88.9'dur.


Modelin, imge birleştirme işlemi gerçekleşmeden önce elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki objelerin kesişim kümesi miktarı 0.366'dır.

Modelin, imge birleştirme işlemi gerçekleşmeden önce elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlar Şekil 4.2'de gösterilmektedir. Burada, kareli hata oranı gerçek piksel koordinatları üzerinden hesaplanmıştır.


Modelin, imge birleştirme işlemi gerçekleştikten sonra elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki obje tespit oranı %77.8'dir.

Modelin, imge birleştirme işlemi gerçekleştikten sonra elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki objelerin kesişim kümesi miktarı 0.223'tür. Tüm set üzerindeki kesişim kümesi miktarı ise 0.842'dir.


Modelin, imge birleştirme işlemi gerçekleştikten sonra elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki objelerin ortalama



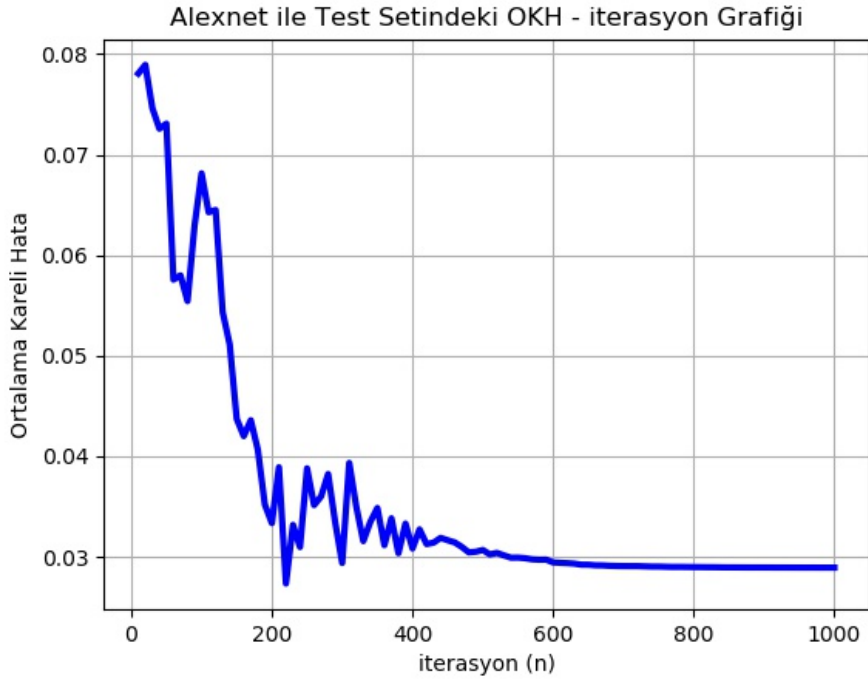
Şekil 4.1: Alexnet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-kesişim kümesi grafiđi.



Şekil 4.2: Alexnet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-ortalama kareli hata grafiđi.



Şekil 4.3: Alexnet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-kesişim kümesi grafiđi.



Şekil 4.4: Alexnet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-ortalama kareli hata grafiđi.

kareli hata miktarı 0.0289'dur. Burada, birleştirilmiş görsellerin boyutları farklılık gösterdiği için piksel değerleri  $[0, 1]$  aralığına normalize edilmiştir.

Ortak enformasyon bloğuna girmeden, sadece sinir ağı blok sonuçlarına göre, uydu görüntüsü ve kamera üzerinden ilgili eşleşmenin yapıldığı görseller Şekil 4.5'te gösterilmiştir.



Şekil 4.5: Alexnet ile ortak enformasyon bloğuna girmeden önce elde edilen uydu ve kamera görüntüsü eşleşmesi.

Şekil 4.5'te yeşil ile işaretli bölgeler önceden belirtilmiş uydu alanlarını gösterirken, mavi ile işaretli bölge sinir ağı sistemin bulunduğu sonuçları göstermektedir. Şekil 4.6 ve 4.7'de bulunan görseller uydu görüntüsü olarak Google Earth üzerinden elde edilmiştir. Şekil 4.5 bulunan eşleşmeler Şekil 4.6 ve 4.7 referans alınarak yapılmıştır.



Şekil 4.6: Google Earth üzerinden alınan bir bina görseli.



Şekil 4.7: Google Earth üzerinden alınan bir bina görseli.

#### 4.1.2 VGG kullanılan sinir ağı eşleşmesi

VGG16 ile çıkartılan özniteliklerden sonra kamera görüntüsü üzerinde uydu objesinin eşleştirilmesi ve koordinatlarının gösterilmesi için iterasyon-hata oranı ve iterasyon-kesişim kümeleri (Intersection of Union, IoU) grafikleri birleştirilmemiş imgeler için Şekil 4.8 ve Şekil 4.9'da gösterilmiştir. Birleştirilmiş imgeler için ise aynı sonuçlar Şekil 4.10 ve Şekil 4.11'de verilmiştir.

Modelin, imge birleştirme işlemi gerçekleşmeden önce elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki objelerin kesişim kümesi miktarı 0.403'tür.

Modelin, imge birleştirme işlemi gerçekleşmeden önce elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlar Şekil 4.9'da gösterilmektedir. Burada, kareli hata oranı gerçek piksel koordinatları üzerinden hesaplanmıştır.

Modelin, imge birleştirme işlemi gerçekleşmeden önce elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki obje tespit oranı %88.9'dur.


Modelin, imge birleştirme işlemi gerçekleştikten sonra elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki objelerin kesişim kümesi miktarı 0.209'dur. Tüm set üzerindeki kesişim kümesi miktarı ise 0.844'tür.

Modelin, imge birleştirme işlemi gerçekleştikten sonra elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki objelerin ortalama kareli hata miktarı 0.0303'tür. Burada, birleştirilmiş görsellerin boyutları farklılık gösterdiği için piksel değerleri  $[0, 1]$  aralığına normalize edilmiştir.


Modelin, imge birleştirme işlemi gerçekleştikten sonra elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki obje tespit oranı %66.7'dir.

Ortak enformasyon bloğuna girmeden, sadece sinir ağı blok sonuçlarına göre, uydu görüntüsü ve kamera üzerinden ilgili eşleşmenin yapıldığı görseller Şekil 4.12'de gösterilmiştir.

Şekil 4.12'de yeşil ile işaretli bölgeler önceden belirtilmiş uydu alanlarını gösterirken, mavi ile işaretli bölge sinir ağı sistemin bulunduğu sonuçları göstermektedir. Şekil 4.13'te bulunan görseller uydu görüntüsü olarak Google Earth üzerinden elde edilmiştir. Şekil 4.12 bulunan eşleşmeler Şekil 4.13 referans alınarak yapılmıştır.

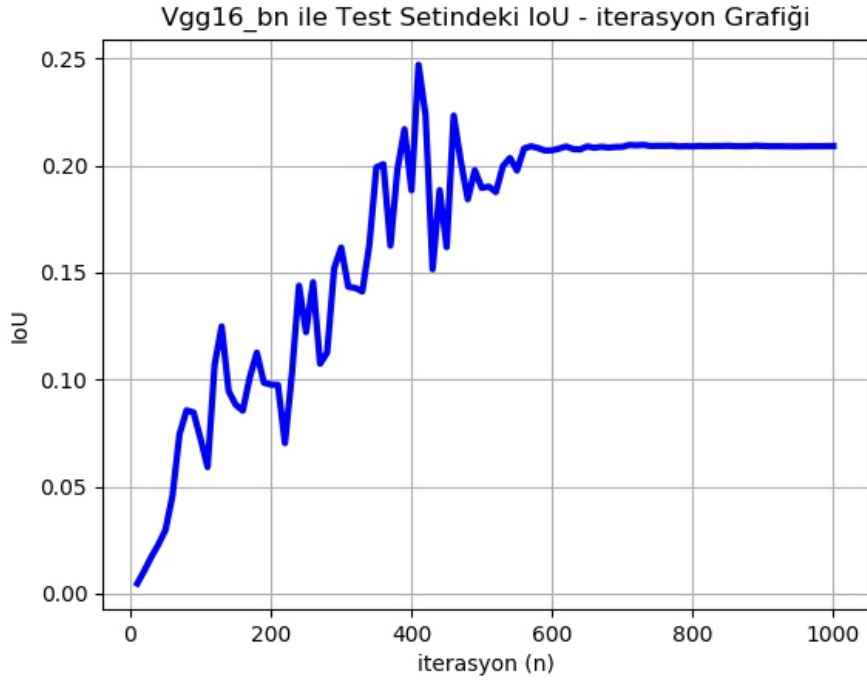


Şekil 4.8: VGG16 ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-kesişim kümesi grafiđi.




Şekil 4.9: VGG16 ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-ortalama kareli hata grafiđi.





Şekil 4.10: VGG16 ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-kesişim kümesi grafiđi.



Şekil 4.11: VGG16 ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-ortalama kareli hata grafiđi.



Şekil 4.12: VGG16 ile ortak enformasyon bloğuna girmeden önce elde edilen uydu ve kamera görüntüsü eşleşmesi.




Şekil 4.13: Google Earth üzerinden alınan bir bina görseli.

### 4.1.3 MobileNet kullanılan sinir ağı eşleşmesi

MobileNet ile çıkartılan özneteliklerden sonra kamera görüntüsü üzerinde uydu objesinin eşleştirilmesi ve koordinatlarının gösterilmesi için iterasyon-hata oranı ve iterasyon-kesişim kümeleri (Intersection of Union, IoU) grafikleri Şekil 4.14, Şekil 4.15, Şekil 4.16 ve Şekil 4.17’de verilmiştir.

Modelin, imge birleştirme işlemi gerçekleşmeden önce elde edilen görseller ile 700 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki objelerin kesişim kümesi miktarı 0.345’tir.

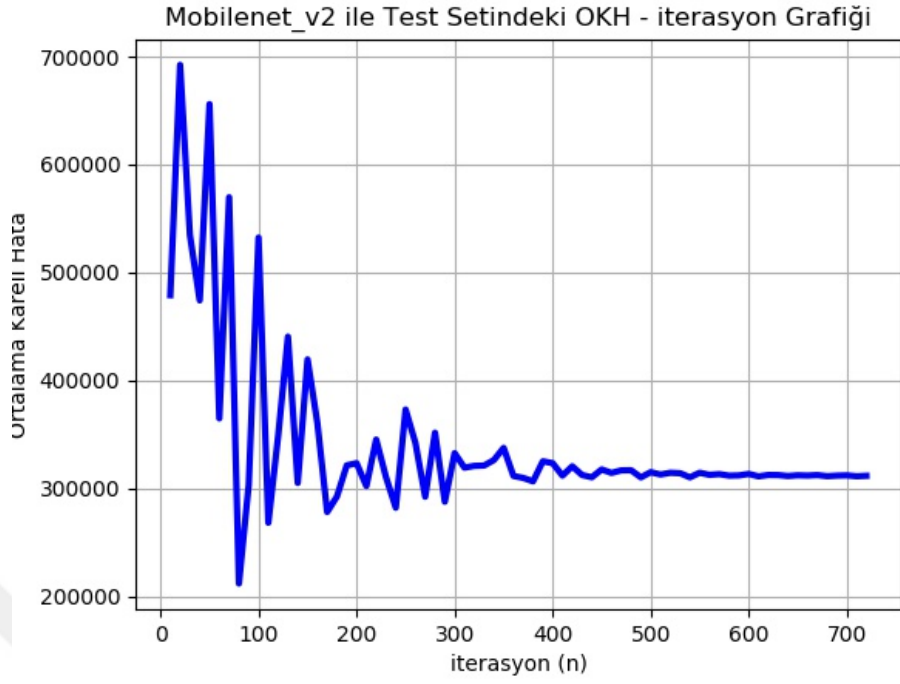


Şekil 4.14: MobileNet ile öznetelik çıkarma işlemi yapılarak elde edilen iterasyon-kesişim kümesi grafiği.


Modelin, imge birleştirme işlemi gerçekleşmeden önce elde edilen görseller ile 700 iterasyon eğitimi sonrasında elde edilen sonuçlar Şekil 4.15’te gösterilmektedir. Burada, kareli hata oranı gerçek piksel koordinatları üzerinden hesaplanmıştır. Test setindeki objelerin ortalama kareli hata miktarı 311463.260’tır.

Modelin, imge birleştirme işlemi gerçekleşmeden önce elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki obje tespit oranı %88.9’dur.

Modelin, imge birleştirme işlemi gerçekleştikten sonra elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki objelerin kesişim kümesi miktarı 0.277’dir. Tüm set üzerindeki kesişim kümesi miktarı ise 0.805’tir.




Şekil 4.15: MobileNet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-ortalama kareli hata grafiđi.



Şekil 4.16: MobileNet ile öznitelik çıkarma işlemi yapılarak elde edilen iterasyon-kesişim kümesi grafiđi.

Modelin, imge birleştirme işlemi gerçekleştirildikten sonra elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki objelerin ortalama kareli hata miktarı 0.0245'tir. Burada, birleştirilmiş görsellerin boyutları farklılık gösterdiği için piksel değerleri  $[0, 1]$  aralığına normalize edilmiştir.



Şekil 4.17: MobileNet ile öznetelik çıkarma işlemi yapılarak elde edilen iterasyon-ortalama kareli hata grafiği.

Modelin, imge birleştirme işlemi gerçekleştirildikten sonra elde edilen görseller ile 1000 iterasyon eğitimi sonrasında elde edilen sonuçlarda test setindeki obje tespit oranı %88.9'dur.

Ortak enformasyon bloğuna girmeden, sadece sinir ağı blok sonuçlarına göre, uydu görüntüsü ve kamera üzerinden ilgili eşleşmenin yapıldığı görseller Şekil 4.18'de gösterilmiştir.


Şekil 4.18'de yeşil ile işaretli bölgeler önceden belirtilmiş uydu alanlarını gösterirken, mavi ile işaretli bölge sinir ağı sistemin bulduğu sonuçları göstermektedir. Şekil 4.19 ve 4.20'de bulunan görseller uydu görüntüsü olarak Google Earth üzerinden elde edilmiştir. Şekil 4.18'de bulunan eşleşmeler Şekil 4.19 ve 4.20 referans alınarak yapılmıştır.



Şekil 4.18: MobileNet ile ortak enformasyon bloğuna girmeden önce elde edilen uydu ve kamera görüntüsü eşleşmesi.



Şekil 4.19: Google Earth üzerinden alınan bir bina görseli.



Şekil 4.20: Google Earth üzerinden alınan bir bina görseli.

#### 4.1.4 AlexNet kullanılan ortak enformasyon eşleşmesi

Alexnet ağını kullanarak çıkartılan öznetelikler ile sinir ağı blok sonuçlarını da kullanarak, ortak enformasyon maksimum olan bölgenin seçildiği ortak enformasyon bloğunun eşleşme görselleri Şekil 4.21’de gösterilmiştir.

Test setinde kullanılan görüntülerin kesişim kümesi miktarı %1.15 azalma göstermiştir. Ortak enformasyon sonucunda beklenen artış AlexNet öznetelik çıkarma algoritması kullanıldığında gözlemlenmemiştir ve sinir ağı sonucu ile yaklaşık olarak aynı çıktıyı vermektedir.



Şekil 4.21: Alexnet ile ortak enformasyon bloğundan sonra elde edilen uydu ve kamera görüntüsü eşleşmesi.

#### 4.1.5 VGG kullanılan ortak enformasyon eşleşmesi

VGG16 ağını kullanarak çıkartılan öznetelikler ile sinir ağı blok sonuçlarını da kullanarak, ortak enformasyon maksimum olan bölgenin seçildiği ortak enformasyon bloğunun eşleşme görselleri Şekil 4.22’de gösterilmiştir.



Şekil 4.22: VGG16 ile ortak enformasyon bloğundan sonra elde edilen uydu ve kamera görüntüsü eşleşmesi.

Test setinde kullanılan görüntülerin kesişim kümesi miktarı %11.08 artış gözlemlenmiştir. Ortalama kareli hata miktarları karşılaştırıldığında ise ortak enformasyon uygulandıktan sonra %1.06 artış gözlemlenmiştir. Bunun sebebi sinir ağı modelinin kareli hatayı azaltmak üzere eğitilmesinden kaynaklanmaktadır. Ortalama kareli hata oranı ortak enformasyon sonucunda küçük bir miktar (%1.06) artmasına rağmen, kesişim kümesi miktarında yüksek bir artış (%11.08) gözlemlenmektedir.



#### 4.1.6 MobileNet kullanılan ortak enformasyon eşleşmesi

MobileNet ağını kullanarak çıkartılan öznetelikler ile sinir ağı blok sonuçlarını da kullanarak, ortak enformasyon maksimum olan bölgenin seçildiği ortak enformasyon bloğunun eşleşme görselleri Şekil 4.23'te gösterilmiştir.



Şekil 4.23: MobileNet ile ortak enformasyon bloğundan sonra elde edilen uydu ve kamera görüntüsü eşleşmesi.

Test setinde kullanılan görüntülerin kesişim kümesi miktarı %6.56 artış gözlemlenmiştir. Ortalama kareli hata miktarları karşılaştırıldığında ise ortak enformasyon uygulandıktan sonra %4.23 azalış gözlemlenmiştir. Hem ortalama kareli hata miktarında hem de kesişim kümesi miktarında, ortak enformasyon bloğu uygulandıktan sonra iyileşme görülmüştür.

Alexnet, VGG16 ve MobileNet sinir ađları kullanıldıktan sonra uygulanan ikinci blok olan ortak enformasyon blođu, genel olarak görüntülerdeki eşleşme oranını arttırmıştır. VGG16 ve MobileNet uygulandıktan sonra, kullanılan ortak enformasyon blođunda görüntüler üzerinde eşleşmelerde artış sağlanırken(%11.08 ve %6.56), Alexnet uygulandıktan sonra kullanılan ortak enformasyon blođunda sinir ađı blođuna yakın bir eşleşme elde edilmiş ve eşleşme ortak enformasyon blođunda %1.15 azalmıştır.





## 5. SONUÇ

Bu çalışmada GPS bilgisinin kaybedildiği yerlerde İHAların seyrüseferine devam edebilmesi ve uçuşların güvenli bir şekilde sürdürülmesini sağlama amacı temel çıkış noktası olmuştur. Çalışma kapsamında on bir adet uydudan alınan görüntülerin, İHA üzerinde yerleştirilmiş kamera ile alınan görüntülerin içinde olup olmadığı incelenmekte ve bulunduğu konum tahmin edilmektedir, bunun için de iki adet sinir ağı bloğu tasarlanmıştır. İHA üzerine yerleştirilmiş kameradan alınan görüntü üzerindeki objeler önceden işaretlenerek, sisteme doğru bilgi olarak verilmiş ve sistemin eğitilmesinde ve sonuçlarda karşılaştırma da doğru bilgiler olarak kullanılmıştır.

Sinir ağı blokları devreye girmeden önce iki görüntü seti üzerinde öznelik çıkarma algoritmaları çalıştırılmaktadır. Bu çalışmada Alexnet, MobileNet ve VGG16 öznelik çıkarma sinir ağları kullanılmış ve çıkarılan özneliklere göre görüntülerin eşleşme performansları değerlendirilmiştir.

Öznelik çıkarma işleminden sonra ilk sinir ağı bloğu ile uydudan alınan görüntülerin, İHA'dan alınan görüntü içerisinde olup olmadığı tespit edilmektedir. On bir adet uydu görüntüsü, İHA'dan gelen görüntüler üzerinde işaretleme işlemi yapılmadan önce, varlık tespiti işleminden geçirilmektedir.

Kamera görüntülerinin içerisinde uydu görüntüsü bulduktan sonra, ikinci sinir ağı bloğu ile konumunun tahmini yapılmaktadır. Bu tahmin sonrası x ve y koordinatları bilinen görüntü İHA'dan alınan görüntü üzerinde işaretlenmektedir.

GPS kaybı yaşanan ortamlarda ve sensör hataları sebebi ile olası yaşanabilecek kaymalarda daha geniş alanda arama yapabilmek adına görüntü birleştirme bloğu tasarlanmıştır. Bu blokla İHA'dan alınan görüntüler birleştirilerek etrafın daha geniş bir görüntüsü elde edilmekte ve bu geniş görüntü içerisinde uydudan alınan görsellerin eşleştirilmesi yapılmaktadır.

Sinir ağı bloklarının tasarımından sonra görüntüler arasında ortak enformasyon hesaplanmaktadır. Ortak enformasyon, piksel renk yeğliliklerinden bağımsız olduğu için, İHA üzerinden alınan görüntünün mevsim şartları değişmiş olsa bile önceden kaydedilmiş uydu görüntülerini İHA'dan alınan görüntüler üzerinde tespit edebilmektedir. Ortak enformasyon hesaplaması öncesinde ikinci sinir ağı bloğunda tespit edilen koordinatların ağırlığı artırılarak, olası yakın ortak enformasyon değer hesaplamalarında, önceden bilinen bilgi ile olması gereken bölgenin ağırlığı artırılmaktadır. Ortan enformasyon hesaplamasından sonra maksimum ortak enformasyona sahip bölge işaretlenmekte ve

hava aracının o bölgenin üzerinde olduđu tespit edilmektedir.

İleriki dönemde yapılabilecek çalışmalar olarak öznelik çıkarma işleminde SIFT (Scale-Invariant Feature Transformation), SURF (Speeded-Up Robust Features) veya HOG (Histogram of Oriented Gradient) gibi algoritmalar kullanılması öngörülmektedir. Ayrıca, daha gürbüz bir sınırlayıcı kutu bulma amacıyla imge bölütleme (segmentation) işlemi algoritmaya dahil edilebilir.



## KAYNAKLAR

- [1] **Lu, Y., Xue, Z., Xia, G.-S., & Zhang, L.** (2018). A survey on vision-based UAV navigation. *Geo-spatial information science*, 21(1), 21–32.
- [2] **DeSouza, G. N., & Kak, A. C.** (2002). Vision for mobile robot navigation: A survey. *IEEE transactions on pattern analysis and machine intelligence*, 24(2), 237–267.
- [3] **Sanfourche, M., Delaune, J., Le Besnerais, G., De Plinval, H., Israel, J., Cornic, P., Treil, A., Watanabe, Y., & Plyer, A.** (2012). Perception for UAV: Vision-Based Navigation and Environment Modeling.
- [4] **Vaman, D.** (2012). TRN history, trends and the unused potential, In *2012 IEEE/AIAA 31st Digital Avionics Systems Conference (DASC)*. IEEE.
- [5] **Conte, G., & Doherty, P.** (2009). Vision-based unmanned aerial vehicle navigation using geo-referenced information. *EURASIP Journal on Advances in Signal Processing*, 2009, 1–18.
- [6] **Mungui'a, R., Urzua, S., Bolea, Y., & Grau, A.** (2016). Vision-based SLAM system for unmanned aerial vehicles. *Sensors*, 16(3), 372.
- [7] **Maier, J., & Humenberger, M.** (2013). Movement detection based on dense optical flow for unmanned aerial vehicles. *International Journal of Advanced Robotic Systems*, 10(2), 146.
- [8] **Cho, D.-M., Tsiotras, P., Zhang, G., & Holzinger, M.** (2013). Robust feature detection, acquisition and tracking for relative navigation in space with a known target, In *AIAA Guidance, Navigation, and Control (GNC) Conference*.
- [9] **Ghannam, S., & Abbott, A. L.** (2013). Cross correlation versus mutual information for image mosaicing. *International Journal of Advanced Computer Science and Applications (IJACSA)*, 4(11).
- [10] **Spilker Jr, J. J., Axelrad, P., Parkinson, B. W., & Enge, P.** (1996). *Global Positioning System: Theory and Applications, Volume I*. American Institute of Aeronautics; Astronautics.
- [11] *GLONASS History*. (n.d.). <https://www.glonass-iac.ru/en/guide/> (alındığı tarih: 06.06.2020)
- [12] *GNSS Frequencies and Signals*. (n.d.). <https://novatel.com/support/known-solutions/gnss-frequencies-and-signals> (alındığı tarih: 07.06.2020)

- [13] *Galileo Frequency Bands*. (n.d.). <https://galileognss.eu/galileo-frequency-bands/> (alındığı tarih: 07.06.2020)
- [14] *Satellite Systems*. (n.d.). <https://novatel.com/an-introduction-to-gnss/chapter-3-satellite-systems> (alındığı tarih: 08.06.2020)
- [15] **Hegarty, C. J., & Chatre, E.** (2008). Evolution of the global navigation satellitesystem (gnss). *Proceedings of the IEEE*, 96(12), 1902–1917.
- [16] *GLONASS History*. (n.d.). <https://news.lockheedmartin.com/2005-09-26-First-Modernized-GPS-Satellite-Built-by-Lockheed-Martin-Launched-Successfully-by-the-U-S-Air-Force> (alındığı tarih: 07.06.2020)
- [17] *GNSS Systems*. (n.d.). <https://novatel.com/an-introduction-to-gnss/chapter-1-gnss-overview/section-1> (alındığı tarih: 08.06.2020)
- [18] *Galileo System*. (n.d.). [https://ec.europa.eu/growth/sectors/space/galileo/launches\\_en](https://ec.europa.eu/growth/sectors/space/galileo/launches_en) (alındığı tarih: 07.06.2020)
- [19] *GNSS+INS Systems*. (n.d.). <https://novatel.com/an-introduction-to-gnss/chapter-6-gnss-ins/gnss-ins-systems> (alındığı tarih: 08.06.2020)
- [20] *Inertial Measurement Units and Inertial Navigation*. (n.d.). <https://www.vectornav.com/support/library/imu-and-ins> (alındığı tarih: 07.06.2020)
- [21] **LeCun, Y., Bottou, L., Bengio, Y., & Haffner, P.** (1998). Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, 86(11), 2278–2324.
- [22] **Krizhevsky, A., Sutskever, I., & Hinton, G. E.** (2012). Imagenet classification with deep convolutional neural networks, In *Advances in neural information processing systems*.
- [23] **Simonyan, K., & Zisserman, A.** (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- [24] **Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H.** (2017). Mobilenets: Efficient convolutional neural networks for mobile vision applications. *arXiv preprint arXiv:1704.04861*.
- [25] **Szeliski, R.** (2010). Computer vision: algorithms and applications. Springer Science & Business Media.
- [26] **Bradski, G.** (2000). The OpenCV Library. *Dr. Dobb's Journal of Software Tools*.
- [27] **Woods, R. P., Cherry, S. R., & Mazziotta, J. C.** (1992). Rapid automated algorithm for aligning and reslicing PET images. *Journal of computer assisted tomography*, 16(4), 620–633.
- [28] **Woods, R. P., Mazziotta, J. C., Cherry, S. R.** Et al. (1993). MRI-PET registration with automated algorithm. *Journal of computer assisted tomography*, 17, 536–536.
- [29] **Hill, D. L., Hawkes, D. J., Harrison, N. A., & Ruff, C. F.** (1993). A strategy for automated multimodality image registration incorporating anatomical

knowledge and imager characteristics, In *Biennial International Conference on Information Processing in Medical Imaging*. Springer.

- [30] **Pluim, J. P., Maintz, J. A., & Viergever, M. A.** (2003a). Mutual-information-based registration of medical images: a survey. *IEEE transactions on medical imaging*, 22(8), 986–1004.
- [31] **Bardera, A., Feixas, M., & Boada, I.** (2004). Normalized similarity measures for medical image registration, In *Medical Imaging 2004: Image Processing*. International Society for Optics and Photonics.
- [32] **Dame, A., & Marchand, E.** (2013). Using mutual information for appearance-based visual path following. *Robotics and Autonomous Systems*, 61(3), 259–270.
- [33] **Pluim, J. P., Maintz, J. A., & Viergever, M. A.** (2003b). Mutual-information-based registration of medical images: a survey. *IEEE transactions on medical imaging*, 22(8), 986–1004.
- [34] *4th Ave Reservoir Capacity Map*. (n.d.). [http://dronemapper.com/sample\\_data/](http://dronemapper.com/sample_data/) (alındığı tarih: 2019)



## ÖZGEÇMİŞ

**Ad-Soyad** : Çağla Şahin  
**Uyruğu** : T.C.  
**Doğum Tarihi ve Yeri** : 09.10.1992 Çankaya  
**E-posta** : cgagaci@etu.edu.tr

### ÖĞRENİM DURUMU:

- **Yüksek Lisans** : 2020, TOBB ETÜ, Elektrik ve Elektronik Müh.
- **Lisans** : 2016, Bilkent Üniversitesi, Elektrik ve Elektronik Müh.

### MESLEKİ DENEYİM VE ÖDÜLLER:

Yıl	Yer	Görev
2016 - Halen	Türk Havacılık ve Uzay Sanayi	Tasarım Mühendisi

Yıl	Yer	Ödül
2018 - 2020	TOBB Ekonomi ve Teknoloji Üniversitesi	Yüksek Lisans ARGE Bursu

**YABANCI DİL:** İngilizce

### TEZDEN TÜRETİLEN YAYINLAR, SUNUMLAR VE PATENTLER:

- **Şahin, Ç.** and Yetik, İ. Ş. (2020). New Navigation System for Unmanned Aerial Vehicles in Global Positioning System-Denied Environments Based On Image Registration with Mutual Information and Deep Learning. *Institute of Navigation (ION ITM 2020)*. San Diego, California