

ÇUKUROVA ÜNİVERSİTESİ

FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZİ

**İnsansız Hava Araçlarının Otokodlayıcı Derin Sinir Ağı
Kullanılarak Arazi Temelli Navigasyon ile Konum Tespiti**

Ahmet Ertuğrul ARIK

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Şubat, 2024

ÇUKUROVA ÜNİVERSİTESİ
FEN BİLİMLERİ ENSTİTÜSÜ

DOKTORA TEZ ONAYI

**İnsansız Hava Araçlarının Otokodlayıcı Derin Sinir Ağı
Kullanılarak Arazi Temelli Navigasyon ile Konum Tespiti**

Ahmet Ertuğrul ARIK

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

Bu Doktora Tezi 16/02/2024 Tarihinde Aşağıdaki Jüri Üyeleri Tarafından Değerlendirilmiş
ve Oy Birliği / Oy Çokluğu ile Kabul Edilmiştir.

Jüri : Doç. Dr. Nuri EMRAHOĞLU (Danışman)
: Prof. Dr. Süha BERBEROĞLU
: Prof. Dr. H. Mustafa KANDIRMAZ
: Prof. Dr. Mehmet Ali ÇULLU
: Prof. Dr. Turgay İBRİKÇİ

**Bu Tez Fen Bilimleri Enstitüsü, Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim
Dalında Hazırlanmıştır.**

Tez No:

Prof. Dr. Sadık DİNÇER
Enstitü Müdürü

**Bu çalışma Çukurova Üniversitesi Bilimsel Araştırma Projeleri Koordinasyon Birimi Tarafından
Desteklenmiştir. -2022-14787**

Not: Bu tezde kullanılan özgün ve başka kaynaktan yapılan bildirişlerin, çizelge ve fotoğrafların kaynak
gösterilmeden kullanımı, 5846 sayılı Fikir ve Sanat Eserleri Kanunundaki hükümlere tabidir.

İÇİNDEKİLER

ÖZ	I
ABSTRACT.....	II
TEŞEKKÜR.....	III
ÇİZELGELER DİZİNİ	IV
ŞEKİLLER DİZİNİ.....	V
SİMGELER VE KISALTMALAR.....	VII
1. GİRİŞ	1
2. ÖNCEKİ ÇALIŞMALAR.....	5
3. MATERYAL VE METOT	13
3.1. Materyal	13
3.1.1. Sinir Ağı İçin Eğitim Verisi toplama- Uydu Verileri ve Haritalar	14
3.1.2. Testlerde Kullanılacak Haritanın Temini	21
3.1.3. Uçuş Test verisi	25
3.1.4. Test bölgesi	28
3.2. Metot	30
3.2.1. Sinir Ağının Eğitim Süreci	30
3.2.2. Şablon Eşleme Algoritması ile Testler	47
4. BULGULAR VE TARTIŞMA	65
4.1. Simülasyon ve Modellemeler.....	65
4.1.1. İki Farklı Uydu Görüntüsü Kullanarak Konum Bulma Simülasyonu:	65
4.1.2. İki Farklı Uydu Görüntüsü Üzerinde Otonom Hareket Simülasyonu	66
4.1.3. Gerçek Dünya Verileri ile Sinir Ağı Model Performanslarının Değerlendirilmesi... ..	68
4.1.4. İleri Düzey Simülasyon Üzerinden Gerçek Uçuş Rotası Testleri	70
4.2. Genel Model Performansı ve Değerlendirmeler	88
5. SONUÇLAR VE ÖNERİLER	91
KAYNAKLAR	93
ÖZGEÇMİŞ	99

İnsansız Hava Araçlarının Otokodlayıcı Derin Sinir Ağı Kullanılarak Arazi Temelli Navigasyon ile Konum Tespiti

Ahmet Ertuğrul ARIK

Danışman: Doç. Dr. Nuri EMRAHOĞLU

Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Anabilim Dalı

ÖZ

Uydu Konum Belirleme Sistemleri (GNSS) ve başta GPS olmak üzere bu sistemlerin sağladığı konumlandırma bilgisi, insansız hava araçları (İHA) navigasyonu için kritik öneme sahiptir. Ancak GNSS sinyalleri, kanyonlar ve yoğun kentsel alanlar gibi bazı ortamlarda engellenebilir, zayıflayabilir veya kasten karıştırılabilir. Bu durum, İHA'ların güvenli ve otonom uçuş kabiliyetlerini olumsuz etkilemektedir.

Bu çalışmanın amacı, GNSS sinyallerine bağımlı kalmadan, karmaşık çevresel koşullarda bile İHA navigasyonu için otokodlayıcı sinir ağlarını kullanmanın etkinliğini araştırmaktır. Otokodlayıcı sinir ağları, görsel verilerden karmaşık temsiller öğrenme konusunda son derece başarılıdır ve bu sayede İHA'nın çevresini algılama ve konumunu belirlemede kullanılabilirler.

Çalışmada, Google Haritalar verileri ve İHA tarafından yakalanan nadir görüntülerinden oluşan bir veri seti oluşturulmuştur. Google Haritalar veri seti kullanılarak, otokodlayıcı sinir ağı eğitilmiştir. Eğitilen sinir ağı temelli algortima, İHA tarafından yakalanan nadir görüntüsünü işlemekte ve bu görüntüyü önceden işlenmiş bir harita üzerinde şablon eşleme algoritmaları ile yüksek doğrulukla konumlandırabilmektedir.

Bu çalışmanın bulguları, GNSS harici İHA navigasyonu için yeni bir yöntem sunmaktadır. Otokodlayıcı sinir ağları temelli navigasyon algoritmaları, İHA'ların daha karmaşık görevlerde GNSS sinyallerinin bozulması ihtimaline karşı yedek bir navigasyon sistemi olarak güvenilir ve etkin bir şekilde kullanılarak bu teknolojinin potansiyelini önemli ölçüde artırabilir.

Gelecekteki araştırmalar, otokodlayıcı sinir ağları temelli İHA navigasyonunun performansını daha da geliştirmeye odaklanabilir. Bu bağlamda, yüksek çözünürlüklü sayısal yükseklik modeli haritalarının kullanımı, daha kapsamlı ve doğru etiketlenmiş veri setleri ile eğitilmeleri, görsel özelliklerin daha iyi öğrenilmesine ve daha sağlam bir navigasyon sistemi geliştirilmesine olanak tanıyabilir. Kalman filtresi gibi yöntemlerin entegrasyonu ise sensör hatalarının ve çevresel belirsizliklerin etkisini azaltarak konum tahminlerinin hassasiyetini ve güvenilirliğini yükseltebilir. Farklı uzamsal çözünürlüklerde haritalar içeren piramit veri yapıları da otokodlayıcıların farklı ölçeklerde görsel bilgileri işleyebilmesine imkân tanıyarak konumlandırma başarımını yükseltebilir. Bu unsurların araştırılması ve geliştirilmesi, otokodlayıcıların İHA navigasyonundaki başarısını önemli ölçüde yükseltme potansiyeline sahiptir. Ek olarak, bu ek faktörlerin gerçek dünya koşullarında test edilmesi ve pratik uygulamalara entegre edilmesi, teknolojinin olgunlaşmasına ve güvenilirliğinin artmasına katkıda bulunacaktır.

Anahtar Kelimeler: Otokodlayıcı Sinir Ağları, Görsel Navigasyon, Yapay Zekâ, İHA Görsel Navigasyon, Bilgisayarlı görü

Location Detection of Unmanned Aerial Vehicles with Terrain-Based Navigation Using Autoencoder Deep Neural Network

Ahmet Ertuğrul ARIK

Advisor: Doç. Dr. Nuri EMRAHOĞLU

Department of Remote Sensing and Geographic Information Systems

ABSTRACT

Global Navigation Satellite Systems (GNSS), primarily GPS, provide critical positioning information for unmanned aerial vehicle (UAV) navigation. However, GNSS signals can be obstructed, weakened, or intentionally jammed in certain environments, such as canyons and dense urban areas. This adversely affects the safe and autonomous flight capabilities of UAVs.

This study aims to investigate the effectiveness of using autoencoder neural networks for UAV navigation in complex environmental conditions, without relying on GNSS signals. Autoencoder neural networks are highly successful in learning complex representations from visual data, and thus can be utilized for UAV environment perception and position estimation.

The study created a dataset consisting of Google Maps data and nadir images captured by the UAV. The autoencoder neural network was trained using the Google Maps dataset. The trained neural network-based algorithm processes the nadir image captured by the UAV and can locate it on a pre-processed map with high accuracy using template matching algorithms.

The findings of this study offer a novel approach for GNSS-independent UAV navigation. Autoencoder neural network-based navigation algorithms can significantly enhance the potential of this technology by serving as a reliable and effective backup navigation system against the possibility of GNSS signal degradation in more complex missions.

Future research can focus on further improving the performance of autoencoder neural network-based UAV navigation. In this context, the use of high-resolution digital elevation model maps, training with more comprehensive and accurately labeled datasets, and better learning of visual features can facilitate the development of a more robust navigation system. Additionally, integrating methods such as the Kalman filter can reduce the impact of sensor errors and environmental uncertainties, thereby enhancing the accuracy and reliability of position estimates. Pyramid data structures containing maps at different spatial resolutions can also enable autoencoders to process visual information at different scales, potentially improving positioning performance. Researching and developing these elements has the potential to significantly enhance the success of autoencoders in UAV navigation. Furthermore, testing these additional factors in real-world conditions and integrating them into practical applications will contribute to the maturation and increased reliability of the technology.

Keywords: Autoencoder Neural Networks, Visual Navigation, Computer Vision, Image Processing, Template Matching Algorithms

TEŞEKKÜR

Bu akademik yolculuğumun her aşamasında, derin bilgi birikimi ve değerli tecrübeleriyle beni aydınlatan, karşılaştığım zorluklarda daima yanımda duran saygıdeğer danışmanım Doç. Dr. Nuri Emrahoğlu'na ve doğru zamanda doğru tavsiyeleri ile akademik çalışmalarımın yönünün şekillenmesinde büyük emeği olan değerli hocam Doç. Dr. Bekir Yiğit Yıldız'a en içten teşekkürlerimi sunarım. Hocalarımla rehberliği, bu çalışmanın temel taşı olmuştur.

Tez sürecinde bilgisiyle beni zenginleştiren, motivasyonumu her zaman yüksek tutan ve dostlukla yanımda olan kıymetli meslektaşım Öğr. Gör. Reha Paşaoğlu'na derin minnettarlığımı ifade etmek isterim. Onun katkıları, bu çalışmanın şekillenmesinde büyük bir etki yaratmıştır.

Ç.Ü. Uzaktan Algılama ve Coğrafi Bilgi Sistemleri Bölümü'ne, tezim için sağladıkları maddi ve akademik destek için Ç.Ü. Bilimsel Araştırmalar Projeleri Birimi'ne ve yönetimine şükranlarımı sunarım.

En son olarak, bu zorlu süreç boyunca sabrı, masum sevgisi ve neşesiyle hayatıma anlam katan, henüz beş yaşında olmasına rağmen benim en büyük ilham kaynağım olan kızım Lara Arık'a ve her daim destekleyici, sevgi dolu eşim Jihan Arık'a sonsuz sevgi ve minnettarlığımı sunarım. Onların varlığı, bu zorlu akademik yolculuğu daha anlamlı ve katlanılabilir kılmıştır.

ÇİZELGELER DİZİNİ

Çizelge 3.1. Eğitim Verisi Olarak Seçilen Şehirlerin Koordinatları	16
Çizelge 4.1. Test sürecinde kullanılan otokodlayıcı sinir ağı modelleri ve başarı yüzdeleri	65
Çizelge 4.2. Modelleme üzerinde belirlenen hedeflerin performans sonuçları.....	67
Çizelge 4.3. otokodlayıcı modellerin performans sonuçları	69
Çizelge 4.4. Şehirsel Alanlarda İHA Navigasyonu İçin Model_4 Otokodlayıcı Modelinin Sonuçları.....	81
Çizelge 4.5. 1. Arazi Uçuşu Sonuçları	82
Çizelge 4.6. 2. Arazi Uçuşu Sonuçları	84
Çizelge 4.7. 3. Arazi Uçuşu Sonuçları	86
Çizelge 4.8. Arazi Alanları Üzerinde Uçuş Sonuçları	87

ŞEKİLLER DİZİNİ

Şekil 3.1. Genel Akış Şeması	14
Şekil 3.2. Görüntü örneklerinin alındığı şehirlerin harita üzerinde konumları	16
Şekil 3.3. Bazı Şehirlerin eğitim için kullanılan görüntü örnekleri sol taraf uydu görüntüsü sağ taraf aynı jeokoordinata karşılık gelen Google maps görüntüsü	21
Şekil 3.4. a) Otokodlayıcı Sinir ağı modelinin uygulanacağı şehir haritası b) şehir haritasıyla aynı koordinatların sayısal yükseklik modeli haritası c) Otokodlayıcı sinir ağı modelinin uygulanacağı arazi haritası d) arazi haritasıyla aynı koordinatların sayısal yükseklik modeli haritası	23
Şekil 3.5. DJI Mavic 2 Pro İnsansız Hava Aracı	26
Şekil 3.6. Şehir alanları test bölgesi	29
Şekil 3.7. Arazi alanları test bölgesi	30
Şekil 3.8. Ön işlemden geçirilmiş eğitim verileri a) Bern b) Houston c) San Jose d) Lyon	34
Şekil 3.9. Bir Derin Sinir Ağır Mimarisi (Bahi & Batouche, 2018)	35
Şekil 3.10. Otokodlayıcı Mimarisi	37
Şekil 3.11.. Örnek bir evrişimli otokodlayıcı sinir ağı mimarisi gösterimi	38
Şekil 3.12.. İha'nın aldığı NADİR görüntü, sinir ağı uygulamadan öncesi ve sonrası	39
Şekil 3.13. Nihai modelin mimarisinin gösterimi	40
Şekil 3.14.. ELU aktivasyon fonksiyonu gösterimi	41
Şekil 3.15. Sinir ağı eğitim sürecinde eğitim ve doğrulama kayı	46
Şekil 3.16. Arazi üzerinde İHA'nın konum belirleme modeli (Duo & Zhao, 2017)	47
Şekil 3.17. Şablon eşleme test süreci akış şeması	48
Şekil 3.18. İha'dan alınan görüntülerin sinir ağı uygulanmadan önce ve sonrası	49
Şekil 3.19. Uzamsal çözünürlük hesaplamak için kullanılan parametrelerin gösterimi(<i>What Is Ground Sampling Distance (GSD) In Photogrammetry?</i> , 2022)	52
Şekil 3.20. İha'nın İrtifa Parametrelerinin Gösterimi	54
Şekil 3.21. Otokodlayıcı sinir ağı uygulanmış haritada İha'nın konumunun gösterimi. Sarı nokta tahmini yeşil nokta GPS verisiyle alınmış konumu göstermekte	56
Şekil 3.22. Testlerin gerçekleştirildiği simülasyon ekranı	60
Şekil 3.23. İki farklı uyduya ve zamana ait haritaların sinir ağı uygulanmadan önce ve sonra gösterimi	61
Şekil 3.24. Gerçek uçuş rotası takip edilen simülasyonun ekran görüntüsü	64
Şekil 4.1. Şehir Üzerindeki Uçuş Rotası ve Görüntülenen Konumlar — Yeşil ok, İnsansız Hava Aracı (İHA) tarafından izlenen GPS güzergahını göstermektedir. Sarı noktalar ise kullandığımız önerilen modelin tahminlerini temsil etmektedir.	71
Şekil 4.2. Şehir Üzerindeki Uçuş Rotası ve Görüntülenen Konumlar	73

Şekil 4.3.	Şehirsel alanda gerçekleştirilen İHA 3. uçuş testinin görselleştirilmesi.....	74
Şekil 4.4.	2 Mayıs 2023'te alınan 181 görüntü için konum tahminleri. Şehir koşullarında %86.7 doğruluk oranı gösterilmektedir.	75
Şekil 4.5.	5. Şehir alanı test uçuşu rotası	76
Şekil 4.6.	6. Test uçuşu rotası gösterimi	77
Şekil 4.7.	7. Test uçuşu rotasının gösterimi	79
Şekil 4.8.	8. Şehir alanı test uçuşunun rotası	80
Şekil 4.9.	13 Ekim 2022'de arazi koşullarında alınan 181 görüntü için konum tahminleri. Toplamda 140 doğru tahmin ile %77.3 doğruluk oranı gösterilmektedir.....	84
Şekil 4.10.	Model 159 doğru, 52 yanlış tahmin yapmıştır. Bu da modelin %79.1 gibi bir başarı yüzdesine sahip olduğunu gösterir.	85
Şekil 4.11.	13 Ekim 2022'de arazi koşullarında alınan 198 görüntü için konum tahminleri. Toplamda 165 doğru tahmin ile %83.3 doğruluk oranı gösterilmektedir.....	87

SİMGELER VE KISALTMALAR

ABN	: Araziye Bağlı Navigasyon
API	: Uygulama Programlama Arayüzü (Application Programming Interface)
BA	: Gruplandırılmış Paket Ayarla (Bundle Adjustment)
CAE	: Evrişimli Otokodlayıcı (Convolutional Autoencoder)
CNN	: Evrişimli Sinir Ağı (Convolutional Neural Network)
CRS	: Coğrafi Referans Sistemi (Coordinate Reference System)
DNN	: Derin Sinir Ağı (Deep Neural Network)
DRL	: Derin Pekiştirmeli Öğrenme
ELU	: Üstel Doğrusal Ünite (Exponential Linear Unit)
GAN	: Üretici Karşıt Ağlar (Generative Adversarial Network)
GNSS	: Küresel Navigasyon Uydu Sistemi (Global Navigation Satellite System)
GPS	: Küresel Konumlandırma Sistemi (Global Positioning System)
GSD	: Yer Örnekleme Mesafesi (Ground Sample Distance)
IMU	: Ataletsel Ölçüm Birimi (Inertial Measurement Unit)
IMw	: Görüntü Genişliği
IoT	: Nesnelerin İnterneti (Internet of Things)
İHA	: İnsansız Hava Aracı
LSTM	: Uzun Kısa Süreli Hafıza (Long Short-Term Memory)
MAE	: Ortalama Mutlak Hata (Mean Absolute Error)
MDP	: Markov Karar Süreci
MSE	: Ortalama Kare Hata (Mean Squared Error)
NCC	: Normalize Edilmiş Çapraz Korelasyon Katsayısı (Normalized Cross-Correlation Coefficient)
OSAA	: Otonom Su Altı Araçları
PMF	: Nokta Kütle Filtresi (Point Mass Filter)
RANSAC	: Rastgele Örnek Konsensüsü (Random Sample Consensus)
RELU	: Dikdörtgensel Doğrusal Ünite (Rectified Linear Unit)
RGB	: Kırmızı, Yeşil, Mavi (Red, Green, Blue)
RMSE	: Kök Ortalama Kare Hata (Root Mean Square Error)
RNN	: Tekrarlayan Sinir Ağı (Recurrent Neural Network)
SAR	: Sentetik Açıklıklı Radar (Synthetic Aperture Radar)
SGD	: Stokastik Gradyan İnişi (Stochastic Gradient Descent)
SIFT	: Ölçek Değişmez Özellik Dönüşümü (Scale-Invariant Feature Transform)
SW	: Sensör Genişliği
SYM	: Sayısal Yükseklik Modeli (Digital Elevation Model)

UAV : İnsansız Hava Aracı (Unmanned Aerial Vehicle)
UTM : Evrensel Transvers Mercator (Universal Transverse Mercator)
VAE : Varyasyonel Otokodlayıcı (Variational Autoencoder)
VTRN : Araziye Bağlı Görsel Navigasyon (Visual Terrain-Relative Navigation)



1. GİRİŞ

Günümüzde, insansız hava araçları (İHA), teknolojik ilerlemenin bir sonucu olarak, çeşitli alanlarda giderek daha fazla önem kazanmaktadır. Bu araçlar, askeri operasyonlardan başlayarak, endüstriyel tesislerin denetiminde kritik altyapıların korunmasından, coğrafi haritalamanın hassas veri toplamasına ve zorlu doğal afet bölgelerindeki arama-kurtarma operasyonlarına kadar geniş bir yelpazede etkinlik göstermektedir (Shakhathreh vd., 2019). İlk askeri kullanımlarının ardından, İHA'ların sivil alanlarda kullanımı, özellikle veri toplama ve izleme kapasiteleri nedeniyle önem kazanmıştır. Valavanis ve Vachtsevanos (2015) gibi araştırmacılar, İHA teknolojisinin nasıl hızla evrildiğini ve sivil uygulamalarda nasıl yeni kapılar açtığını gözler önüne sermiştir (Valavanis & Vachtsevanos, 2015). Bu, İHA'ların geniş kullanım yelpazesini ve teknolojik evrimini anlamak için kritik bir perspektiftir.

Örneğin, İHA'lar, orman yangınlarının erken tespiti ve izlenmesinde veya büyük ölçekli tarım arazilerinde verimliliği artırmak için kullanılmaktadır. Özellikle İHA'ların otonom uçuş yetenekleri, onların seyrüsefer (navigasyon) kapasitelerini ön plana çıkarmıştır. Seyrüsefer için yaygın olarak kullanılan yöntemler, uydu bazlı konumlandırma sistemleridir (örn., GPS, GLONASS). Ancak, bu harici veri kaynaklarına olan bağımlılık, özellikle GPS sinyallerinin bloke edilmesi veya karıştırılmasının mümkün olduğu askeri operasyonlar gibi gerçek dünya koşullarında ciddi zayıf noktalar oluşturmaktadır (Khan vd., 2021). Ayrıca, GPS sinyalleri şehir merkezleri gibi yoğun yapılaşmış alanlarda veya doğal engellerin bulunduğu yerlerde güvenilir olmayabilir. Bu durum, İHA'ların kritik görevlerde kullanımını sınırlayan önemli bir engel teşkil etmektedir.

Özellikle, bu çalışmada ele alınacak olan dahili sensörlere dayalı sistemler, İHA'ların GPS sinyallerine erişiminin mümkün olmadığı veya güvenilir olmadığı durumlarda kritik önem taşımaktadır (Arafat vd., 2023). Bu sistemler, örneğin karmaşık kentsel yapılar içinde veya yoğun ormanlık alanlarda, İHA'ların yerini hassas bir şekilde belirleyebilir ve bu sayede araştırma, kurtarma ve keşif görevlerini daha etkin bir biçimde yerine getirebilirler. Dahası, bu çalışma kapsamında geliştirilecek otokodlayıcı sinir ağı tabanlı algoritmalar, İHA'ların çevresel faktörler ve manevra kabiliyetleri göz önünde bulundurularak daha karmaşık rotaları bağımsız olarak planlayabilmesine olanak tanıyacak, bu da İHA kullanımının potansiyelini önemli ölçüde artıracaktır.

Bu algoritmaların önemi, özellikle dahili sensörlere dayalı konum tespiti yöntemlerinin geçmişte karşılaştığı zorluklar ışığında daha da belirginleşmektedir (Farrell & Barth, 1999). Bu zorluklar, özellikle ışık değişiklikleri, mevsimsel değişimler ve sensör kalitesindeki farklılıklar gibi faktörlerle ilgilidir. Bu faktörler, anlık görüntü ve dahili harita arasında doğru bir eşleştirme yapılmasını engeller ve İHA'ların navigasyon kabiliyetlerini sınırlar. Ancak, derin öğrenme ve özellikle otokodlayıcı (autoencoder) algoritmalarının son yıllarda gösterdiği başarı, bu eşleştirme probleminin üstesinden gelmede önemli bir fırsat sunmaktadır (Goodfellow vd., 2016). Bu teknolojik ilerleme, navigasyon sistemlerinin doğruluk ve güvenilirliğini önemli ölçüde artırma

potansiyeline sahiptir. Otokodlayıcılar, haritadaki gereksiz detayları (örneğin gölgeler) filtreleyerek, gürültüden arındırılmış bir harita elde etmek için kullanılabilir (Vincent vd., 2010). Bu işlem, İHA'nın anlık olarak aldığı görüntü ile harita arasında daha doğru bir eşleşmeye olanak tanır ve İHA'ların karmaşık ortamlarda daha etkin ve güvenilir bir şekilde navigasyon yapmasını mümkün kılar (Lu vd., 2018). Bu teknolojik yenilik, İHA'ların daha zorlu ve değişken çevresel koşullarda, özellikle GPS sinyallerinin güvenilir olmadığı veya erişilemez olduğu durumlarda, bağımsız navigasyon kabiliyetlerini önemli ölçüde geliştirebilir. Bu gelişme, İHA teknolojisinin kullanım alanlarını genişletir ve onların operasyonel verimliliğini ve güvenliğini artırır, böylece daha zorlu görevlerde başarıyla kullanılmalarını sağlar.

Bu çalışmada Küresel Uydu Navigasyon Sistemleri (GNSS) olmayan ortamlarda İnsansız Hava Araçları'nın etkin navigasyon kabiliyetlerini geliştirmek amacıyla otokodlayıcı sinir ağı teknolojisinin kullanımı araştırılmaktadır. Araştırmanın temel hedefi, otokodlayıcı tabanlı görsel navigasyon sistemlerinin, İHA'ların karmaşık ve değişken çevre koşullarında GPS ve GNSS'e bağımlı olmaksızın nasıl daha bağımsız güvenilir navigasyon yapabileceğini göstermektir. Bu çalışma, İHA teknolojisinin uygulama alanlarını genişletmek ve zorlu görevlerde daha etkili kullanımını sağlamak açısından kritik bir adımdır. Araştırma, otokodlayıcı sinir ağlarıyla gerçekleştirilen görsel navigasyonu merkeze alarak, geleneksel GNSS tabanlı sistemlerin sınırlılıklarını aşmayı hedeflemektedir. GNSS sistemlerinin karşılaştığı zorluklar "güneş aktivitesi, teknik aksaklıklar ve sahte sinyaller gibi (Kerns vd., 2014)" İHA'ların navigasyon kabiliyetlerini sınırlayabilir ve risk oluşturabilir. Bu bağlamda, alternatif navigasyon sistemlerine duyulan ihtiyaç artmaktadır.

Ayrıca bu araştırmada, İHA'ların zorlu çevre koşullarında başarılı navigasyon performansı sergileyebilmeleri için otokodlayıcı sinir ağlarının nasıl etkin bir şekilde entegre edilebileceği derinlemesine incelenmektedir. İHA teknolojisinin artan önemi göz önüne alındığında, bu araştırma, özellikle GPS erişimi sınırlı veya mümkün olmayan durumlarda, İHA'ların navigasyon yeteneklerini geliştirme potansiyeline odaklanmaktadır. Otokodlayıcılar, gürültüyü filtreleyerek ve çevresel algıyı iyileştirerek, İHA'ların anlık görüntü verilerini daha etkin işlemelerine ve iç haritalarla doğru eşleşmeler yapmalarına olanak tanıyabilir. Bununla birlikte bu çalışmada otokodlayıcı tabanlı yaklaşımların, İHA'ların görsel navigasyon kabiliyetlerini nasıl genişletebileceği ve GPS bağımlılığından uzaklaşarak daha bağımsız ve güvenilir bir navigasyon sistemi oluşturulmasına nasıl katkıda bulunabileceği araştırılmaktadır. Literatürdeki çalışmaların ışığında, bu yaklaşımın İHA teknolojisinin kullanım alanlarını genişletme ve daha zorlu görevlerde başarı sağlama potansiyeli değerlendirilecektir.

Otokodlayıcılar, yapay sinir ağlarının bir türü olarak, girdi verisini sıkıştırıp düşük boyutlu bir temsilini oluşturma yetenekleriyle öne çıkarlar. Özellikle yüksek boyutlu görsel verilerin işlenmesinde son derece önemlidir. Pintelas ve arkadaşları tarafından yapılan "A Convolutional Autoencoder Topology for Classification in High-Dimensional Noisy Image Datasets" başlıklı

çalışma, derin öğrenme modellerinin gürültülü ve yüksek boyutlu görüntü veri setlerinde sınıflandırma yaparken karşılaştığı zorlukları ele almakta ve otokodlayıcıların bu sorunları çözmede etkin bir araç olduğunu vurgulamaktadır (Pintelas vd., 2021). Bu çalışmada, otokodlayıcıların bu benzersiz özelliklerinin, İHA'ların görsel navigasyonunda nasıl kullanılabileceği ve GPS bağımlılığından uzak, daha güvenilir ve bağımsız bir navigasyon sistemi sağlamada nasıl bir avantaj sunabileceği detaylıca incelenecektir. Özellikle, İHA'ların karmaşık ve değişken çevre koşullarında doğru navigasyon yapabilmesi için otokodlayıcıların nasıl kritik bir role sahip olabileceği, bu çalışmanın temel odak noktalarından biridir. Bu teknolojinin potansiyeli, İHA'ların operasyonel verimliliğini ve güvenliğini artıracak, aynı zamanda daha zorlu görevlerde etkin bir şekilde kullanılmalarını sağlayacak yenilikçi uygulamalara yol açabilir.

Bu çalışmanın temel hedeflerinden biri de GPS sinyalleri mevcut olmadığında veya kesintiye uğradığında etkin bir yedek navigasyon sistemi olarak otokodlayıcı sinir ağlarının görsel navigasyon alanındaki potansiyelini keşfetmek ve bu teknolojiyi kullanarak İHA'ların GPS olmayan ortamlarda etkili bir şekilde navigasyon yapabilmeleri için bir model ve algoritma geliştirmektir. Bu hedefler, otokodlayıcıların geleneksel navigasyon sistemlerine alternatif olarak ne gibi yenilikçi ve etkili çözümler sunabileceğini ortaya koymayı amaçlamaktadır. Çalışma, giriş, literatür incelemesi, metodoloji, bulgular ve tartışma ve sonuçlar olmak üzere beş ana bölüme ayrılmıştır. Literatür incelemesi bölümünde, navigasyon araçlarının ve otokodlayıcıların mevcut kullanımının yanı sıra, İHA'ların görsel navigasyon alanındaki yenilikçi uygulamalarına odaklanılacaktır. Metodoloji-Yöntem bölümünde, otokodlayıcıların şablon eşleme yöntemleri ile (Brunelli, 2009) uygulanma süreci ve bu yaklaşımın İHA navigasyon sistemlerinde nasıl bir fark yaratabileceği detaylı bir şekilde incelenecektir.

GPS'ye olan aşırı bağımlılığın azaltılması ve İHA'ların zorlu çevresel koşullarda daha geniş bir kullanım yelpazesine sahip olması potansiyeli, bu çalışmanın ana motivasyonudur. Otokodlayıcı sinir ağlarının karmaşık problemleri çözmedeki başarısı, bu teknolojinin İHA'ların görsel navigasyonunda nasıl yenilikçi bir yaklaşım sunabileceği fikrini doğurmuştur. İHA'lar, başlangıçta askeri amaçlar için tasarlanmış olsalar da günümüzde tarım, araştırma, kurtarma operasyonları ve çevresel izleme gibi birçok sivil uygulamada kullanılmaktadır. Bu çeşitli uygulama alanları, otokodlayıcı tabanlı görsel navigasyon sistemlerinin geliştirilmesinin, İHA'ların performansını ve uygulama yelpazesini nasıl önemli ölçüde genişletebileceğini göstermektedir.

Son yıllarda yapılan araştırmalar, arazi tabanlı görsel navigasyonun potansiyeline ve mevcut zorluklarına odaklanmıştır. Ancak, bu çalışma, otokodlayıcı sinir ağları ve şablon eşleme temelli görsel navigasyonun birleştirilmesiyle, uydu destekli navigasyon imkânı olmadığında navigasyonun mümkün olup olmadığını araştırmayı amaçlamaktadır. Bu yaklaşım, İHA teknolojisini sadece operasyonel verimliliği artırmakla kalmayıp, daha zorlu ve çeşitli görevlerde kullanımını mümkün kılacak şekilde dönüştürebilir.



2. ÖNCEKİ ÇALIŞMALAR

Yapılan çalışmalara baktığımızda, Irani'nin çalışmasına göre TomaHawk füzelerinin seyrüsefer yeteneği olarak öncelikle arazinin görüntüsü füze yüklenir ve daha sonra füzenin nadir görüntü alan kamerasının anlık kaydettiği görüntü ile harita bir korelasyona tabi tutulur ve en çok korelasyon bulunan alan muhtemel füzenin o anki konumu olarak hesaplanır (Irani & Christ, 1994). Burada da karşılaşılan sorunlar; şablon eşleme (template matching) yaparken arazinin alındığı andaki görüntüsü ile füzenin görüntüsü arasında oluşacak farklardan (zamana göre gölgelerin oluşması ve farklılaşması, mevsimlerin değişmesi ile bitki örtüsünün değişmesi vs.) dolayı korelasyonun düşük çıkmasıdır. Bu soruna çözüm olarak o tarihlerde arazi görüntüsü ile anlık görüntü bir tür ön işleme tabi tutulur ve korelasyonun daha doğru olması amaçlanır.

Guan ve Bai (2012) 'GPU Hızlandırmalı Gerçek Zamanlı Kendi Kendine Yeterli İHA Görsel Navigasyon Sistemi' başlıklı çalışması, GPS bağlantısının kesildiği durumlarda İHA navigasyon sistemlerini desteklemek için coğrafi olarak referanslanmış hava fotoğraflarının kullanımını önermektedir (Guan & Bai, 2012). Bu çalışma, doğal işaretlerin izlenmesi ve SURF algoritmasına dayalı bir görüntü eşleştirme yöntemi sunar. Ancak, bu yaklaşım, özellikle yeni nesil derin öğrenme tekniklerini ve gelişmiş derin sinir ağlarını kullanmamaktadır. Bu, özellikle kentsel gibi karmaşık ve dinamik çevrelerdeki navigasyon problemlerini çözmede sınırlı bir etkinlik sunabilir.

Guan ve Bai'nin yönteminin aksine bu çalışmada, yeni nesil derin sinir ağlarına dayanan yaklaşımlar ele alınmaktadır. Bu modern teknikler, Guan, Bai ve diğerlerinin çalışmasında kullanılan geleneksel algoritmalara göre daha karmaşık çevresel özelliklerin işlenmesi ve dinamik engellere daha etkili bir şekilde adapte olabilmesi gibi avantajlar sunmaktadır. Bu nedenle, bu çalışmadaki yöntemler, İHA navigasyon sistemlerinin karmaşık çevresel koşullar altında daha doğru ve güvenilir bir performans sergilemesini sağlamak için kritik öneme sahiptir.

Yapılan başka bir çalışmada, Strelow ve Touchberry (2012) insansız hava araçlarının kentsel ortamlarda GPS olmayan durumlarda nasıl navigasyon yapabileceğine dair bir yöntem ve sistem sunmuşlardır. Bu yöntem, bir Global Konumlandırma Sistemi (GPS) destekli İHA'nın kentsel bir ortam üzerinde belirli bir yükseklikte uçuşunu ve GPS erişimi engellenmiş bir başka İHA'nın bu yükseklikten daha düşük bir seviyede uçuşunu içerir. İki İHA arasında operasyonel bir iletişim kurularak, her iki araçtan da alınan görüntüler arasında eşleştirmeler yapılır. Bu eşleştirmeler, GPS erişimi engellenmiş İHA'nın mevcut konumunun hesaplanmasında kullanılır. Bu yaklaşım, özellikle kentsel alandaki yüksek binaların GPS sinyalinin engellenmesi gibi durumlarda, düşük yükseklikte uçan İHA'nın navigasyonuna yardımcı olmaktadır (Strelow & Touchberry, 2012).

Son yıllarda, araziye bağlı navigasyon (ABN) teknolojileri, GNSS'in erişilemediği koşullarda özellikle kritik dönüş görevleri için merkezi bir öneme sahip olmuştur. Bu teknoloji, çeşitli sensörlerden elde edilen yerel arazi ölçümlerini, var olan haritalarla birleştirerek, çevreye özgü bir hata payı ile konum belirleme yeteneğine sahiptir. Ancak, bu teknolojinin uygulaması, yüksek

doğruluk ve yoğun veri gereksinimleri nedeniyle, gelişmiş sensör sistemleriyle sınırlı kalmıştır. Bu durum, özellikle insansız hava araçları (İHA) gibi platformlarda, enerji, ağırlık ve maliyet kısıtlamaları nedeniyle daha da belirginleşmiştir.

Bu çerçevede, Meduna ve arkadaşlarının 2008 yılındaki çalışması, ABN teknolojisindeki sensör füzyonu yeteneklerini geliştirmeyi amaçlamıştır (Meduna vd., 2008). Bununla birlikte, bu çalışma, İHA'lar için derin öğrenme yöntemlerinin, özellikle evrişimli otokodlayıcı sinir ağları gibi tekniklerin potansiyelini tam olarak keşfetmemiştir. Geliştirilen entegre filtreleme yapısı ve sensör füzyonuna dayalı performans tahmin metodolojileri, ABN'nin uygulanabilirliğini artırmakla birlikte, görsel navigasyon ve derin öğrenme teknikleri ile olan tam entegrasyon potansiyelini değerlendirmemiştir.

Ayrıca, bu araştırmada otonom su altı araçları (OSAA) üzerinde yapılan denemeler, İHA'lar için doğrudan uygulanabilir sonuçlar sağlamamaktadır. İHA'ların karşılaştığı çevresel ve operasyonel zorluklar, OSAA'larından farklı olabilir (Meduna, 2011). Bu nedenle, ABN teknolojilerinin İHA'lar için etkin bir şekilde kullanılabilmesi, özelleşmiş ve daha geniş kapsamlı sensör füzyonu yaklaşımlarını içeren araştırmalar gerektirmektedir. Bu tür araştırmalar, İHA'ların karşılaşılabileceği özgül koşulları daha iyi anlamak ve bu platformlar için uyarlanmış, daha etkin navigasyon çözümleri geliştirmek için hayati önem taşımaktadır.

Wang ve arkadaşları (2013), GPS olmayan ortamlarda küçük insansız hava araçları (İHA) için görüş destekli atalet navigasyonu konusunda önemli bir katkıda bulunmuşlardır (Wang vd., 2013). Çalışmalarında, İHA'nın hareketini tahmin etmek için bir atalet ölçüm birimi (IMU) ve bir monoküler kamera kombinasyonu kullanılmıştır. Bu yaklaşım, IMU'nun hız ve konum tahminlerinin zamanla biriken hatalarını düzeltmek için kameralı gözlemleri kullanarak GPS sinyalinin bulunmadığı durumlarda İHA'nın konumunu ve hızını doğru bir şekilde tahmin etmeyi mümkün kılar. Ancak, bu metodolojinin bazı sınırlamaları vardır. Örneğin, monoküler kamera sistemi, derinlik algılama konusunda sınırlıdır ve karmaşık veya dinamik çevrelerde doğru yer belirleme konusunda zorluklar yaşayabilir. Ayrıca, IMU ve kamera verilerinin entegrasyonu, senkronizasyon ve veri füzyonu açısından zorluklar içerebilir, bu da navigasyon doğruluğunu etkileyebilir. Wang ve arkadaşlarının çalışması, İHA navigasyonu için alternatif çözümlere yönelik önemli bir adım olmasına rağmen, bu tekniklerin daha karmaşık ve dinamik ortamlarda uygulanabilirliğinin daha fazla araştırılması gerekmektedir.

Kim ve arkadaşları yaptıkları çalışmayla, GPS erişiminin olmadığı ortamlarda sabit kanatlı insansız hava araçları (İHA) için gerçek zamanlı görsel navigasyon sistemini tanıtmaktadır (Kim vd., 2014). Araştırmacılar, görüntü işleme sonuçlarını barometre ve atalet sensör ölçümleriyle birleştirerek bir görüntü destekli navigasyon sistemi oluşturmak için genişletilmiş bir Kalman filtresi kullanmışlardır. Bu sistem, bir ortalama kayma(mean-shift) nesne izleme algoritması kullanarak, navigasyon filtresine piksel ölçümleri sağlayan bütünleşik bir görüntü sistemine sahiptir. Uçuş

testleriyle doğrulanan bu yöntem, İHA'nın GPS verisi olmadan bir hedefin etrafında dönmeyi sürdürebildiğini göstermektedir.

Ancak, bu çalışma, derin sinir ağları gibi son teknolojik gelişmeleri kullanmamaktadır. Derin sinir ağları, görüntü işleme ve nesne tanıma konularında önemli ilerlemeler sağlamıştır ve bu teknolojilerin kullanılması, İHA'ların navigasyon yeteneklerini daha da geliştirebilir. Bu nedenle, bu çalışmanın, derin öğrenme tekniklerinin potansiyel avantajlarını dikkate almayarak, İHA navigasyonu için mevcut ve gelecekteki çözümler arasındaki boşluğu tam olarak kapatamayabileceği belirtilebilir.

Wei ve arkadaşlarının (2022) çalışması, İHA'ların görüntü tabanlı iki boyutlu düzlem navigasyonu üzerine kapsamlı bir inceleme sunmakta ve özellikle Varyasyonel Otokodlayıcı (VAE) tabanlı algoritmanın etkinliğini vurgulamaktadır. Çalışma, farklı zorluk seviyelerine sahip çeşitli ortamlarda eğitim verilmiş üç farklı algoritma tipini karşılaştırmıştır: doğrusal regresyon tabanlı algoritma, uçtan uca sinir ağı algoritması ve VAE tabanlı algoritma. Bu algoritmaların performans karşılaştırılması, VAE tabanlı algoritmanın diğerlerine göre daha düşük müdahale oranı ve daha uzun mesafeleri hata olmadan uçabilme yeteneğine sahip olduğunu ortaya koymaktadır.

Ancak, çalışmanın eleştirel yönde genel bir değerlendirmesi yapılırken, doğrusal regresyon ve uçtan uca sinir ağı algoritmalarının kendi içindeki sınırlamalarına ve uygulanabilirliklerine odaklanmak önemlidir. Örneğin, doğrusal regresyon tabanlı algoritmanın karmaşık navigasyon senaryolarında yeterince esnek olmaması ve dinamik ortamlarla başa çıkmakta zorlanması mümkündür. Uçtan uca sinir ağı algoritmaları ise, genellikle büyük miktarda veriye ihtiyaç duyarlar ve eğitim süreçleri zaman alıcı ve kaynak tüketici olabilir. Ayrıca, bu tür algoritmaların karar verme süreçleri genellikle "kara kutu" olarak kabul edilir ve bu da algoritmaların nasıl çalıştığını anlamak ve hata ayıklamak açısından zorluklar yaratabilir.

Sonuç olarak, Wei ve arkadaşlarının çalışması, İHA navigasyonu için farklı algoritma tiplerinin karşılaştırmalı analizi açısından önemli bir katkı sağlamasına rağmen, bu algoritmaların karmaşık ve dinamik gerçek dünya senaryolarında uygulanabilirliği ve etkinliği konusunda daha fazla araştırmaya ihtiyaç duyulmaktadır. Özellikle, doğrusal regresyon ve uçtan uca sinir ağı algoritmalarının gerçek zamanlı navigasyon senaryolarında nasıl performans gösterdikleri, veri gereksinimleri ve eğitim süreçlerinin karmaşıklığı gibi faktörler, bu algoritmaların pratik uygulanabilirliği açısından önemli hususlardır. Wei ve arkadaşlarının çalışması, bu algoritmaların potansiyelini ve sınırlamalarını ortaya koymakla birlikte, bu teknolojilerin daha geniş çaplı ve karmaşık uygulamalar için optimizasyon ve geliştirme gerektirdiğini de göstermektedir. Bu nedenle, İHA navigasyon sistemlerinin geliştirilmesi alanında ilerleme kaydetmek için, bu tür algoritmaların gerçek dünya koşullarında nasıl adapte edilebileceği ve iyileştirilebileceği üzerine ek araştırmalara ihtiyaç duyulmaktadır. (Wei vd., 2022).

Fragoso, Lee, McCoy ve Chung (2021), İnsansız Hava Araçları için Visual Terrain-Relative Navigation (VTRN) konusunu ele alır. Bu çalışmada, yazarlar, bir İHA kamerası görüntüsünü coğrafi

referanslı ortofotoğraflarla eşleştiren ve kamera görüntüsü ve harita arasında önemli mevsimsel görünüm farkına (kış-yaz) karşı dirençli bir eğitilmiş evrişimli sinir ağı modeline dayanan bir yer belirleme çözümü önerirler. Bu çözüm, mevsimsel görüntüleri, geleneksel algoritmaların değişiklik yapmadan kullanabileceği stabil, değişmez bir alana dönüştürür. Bu dönüşüm, eski yaklaşımların geometrik yapısını ve belirsizlik tahminlerini korur ve aşırı mevsimsel değişiklikler altında üstün performans gösterirken, eğitilmesi kolay ve yüksek derecede genelleştirilebilir olur. Bu çalışma, İHA'ların bilinmeyen ve karmaşık ortamlarda otonom navigasyon yeteneklerini geliştirmek için önemli bir kaynak olarak değerlendirilebilir (Fragoso vd., 2021).

Bianchi ve Barfoot'un çalışmalarında, İHA'ların uydu görüntülerini kullanarak konumlarını belirlemek için otokodlayıcılar kullanılmaktadır (Bianchi & Barfoot, 2021). Fakat, Bianchi ve Barfoot'un yaklaşımından farklı olarak bu çalışmada ele alınan metodoloji, girdi ve çıktı verileri arasında doğrudan bir eşleşme olmamasına rağmen aralarındaki ilişkiyi öğrenen çapraz otokodlayıcıların kullanımına dayanmaktadır. Çapraz otokodlayıcılar, uydu verilerini işleyerek ve bu verileri doğrudan karşılaştırılabilir, basitleştirilmiş etiketlere dönüştürerek, algoritmaların karmaşık gerçek dünya koşullarında daha hassas ve etkin navigasyon yapmalarını sağlar. Bu yaklaşım, İHA'ların kentsel yapıları daha detaylı algılamasına ve bu yapılarla daha sofistike bir etkileşimde bulunmasına imkân tanır. Böylelikle, bu çalışmada önerilen çapraz otokodlayıcı tabanlı metodoloji, geleneksel otokodlayıcıların ötesine geçerek, İHA navigasyonu ve görsel algılama kabiliyetlerini önemli ölçüde geliştirmeyi hedeflemektedir.

Kinnari ve arkadaşlarının 2023 yılında gerçekleştirdikleri “LSVL: Large-scale season-invariant visual localization for UAVs” başlıklı çalışması, İHA'ların GNSS sistemlerine alternatif olarak görsel yer belirleme teknikleri kullanmasını ele almaktadır (Kinnari vd., 2023). Bu araştırma, mevsimsel görünüm değişikliklerini tolere edebilecek şekilde düzlemsel haritalar kullanarak çalışan yoğunlaştırılmış öznitelikleri öğrenen bir İHA görüntüsünden harita eşleştirme yöntemi sunmaktadır. Ayrıca, İHA'nın görsel yer belirleme sürecinde durum tahminini bir nokta kütle filtresi (Point Mass Filter- PMF) kullanarak gerçekleştiren bir yaklaşımı entegre etmektedir.

Kinnari ve arkadaşlarının 2023 yılındaki araştırması, bu çalışma ile bazı temel yönleriyle, özellikle de düzlemsel haritalama teknolojileri kullanımı açısından örtüşmektedir. Ancak, bu çalışma öncelikli olarak büyük ölçekli haritalama ve mevsimsel değişimlere odaklanırken, otokodlayıcı sinir ağları daha karmaşık çevresel özellikleri daha az sistem kaynağı tüketerek ve daha yüksek performansla analiz edebilir. Bu kapasite, özellikle karmaşık çevrelerde, mevcut yöntemlere kıyasla daha etkili ve verimli bir çözüm sunabileceğini göstermektedir.

Ayrıca, Kinnari'nin çalışmasında kullanılan algoritmalar ve durum tahmini yöntemleri, otokodlayıcı tabanlı yaklaşımların sağladığı verimlilik ve hız avantajlarına sahip olmayabilir. Otokodlayıcılar, özellikle kısıtlı sistem kaynaklarıyla çalışırken, düşük hesaplama gücü gereksinimleriyle karmaşık görsel verileri etkili bir şekilde işleyebilir ve gerçek zamanlı navigasyon uygulamaları için ideal bir seçenek sunabilir. Sonuç olarak, bu çalışmada ele alınan otokodlayıcı

tabanlı yaklaşım, Kinnari'nin çalışmasında ele alınan mevsimsel koşullara dayanıklılık özelliği ile birleştirildiğinde, İHA navigasyon sistemleri için daha kapsamlı ve etkili bir çözüm oluşturabilir.

Jaimes, Ferreira ve Castro'nun 2022 tarihli "Unsupervised Semantic Segmentation of Aerial Images With Application to UAV Localization" başlıklı çalışması, insansız hava araçları (İHA) için semantik segmentasyonun önemini vurgulamaktadır (Jaimes vd., 2022). Yazarlar, etiketlenmiş veri setlerinin sınırlı olduğu durumlarda, önceden etiketlenmiş bir veri setine ihtiyaç duymadan semantik segmentasyon yapabilen tamamen denetimsiz bir yöntem önermektedirler. Bu yaklaşım, özellikle etiketleme sürecinin zaman alıcı ve maliyetli olduğu durumlar için cazip bir alternatif sunmaktadır.

Ancak, bu çalışmanın da insansız hava araçları için görsel navigasyon bağlamında bazı sınırlılıkları ve eleştirel noktaları bulunmaktadır. Öncelikle, çalışma genel görüntü sınıflandırma problemlerine odaklanmış olup, İHA'ların karşılaştığı özgül zorlukları veya senaryoları ele almamaktadır. İHA'ların dinamik ortamlarda, değişken hava koşullarında ve farklı yüksekliklerde gerçekleştirdiği görsel navigasyon, ek zorlukları beraberinde getirir. Bu nedenle, Jaimes ve arkadaşlarının önerdiği yaklaşımın, bu özgül zorlukları ele almadığı için, İHA'lar için görsel navigasyon bağlamında tam olarak uygulanabilir olup olmadığı konusunda soru işaretleri bulunmaktadır.

Hou ve arkadaşlarının 2021 tarihli çalışması, Küresel Navigasyon Uydu Sistemleri'nden (GNSS) bağımsız olarak İnsansız Hava Araçları'nın (İHA) konumlandırılması problemine odaklanmaktadır. Bu araştırmada, GNSS olmayan ortamlarda, İHA'ların konum tahmininde yüksek doğruluk sağlamak amacıyla, uydu görüntülerinin derin öğrenme teknikleriyle desteklenen yeni bir konumlandırma metodu geliştirilmiştir. Yöntem, coğrafi koordinatlar ve Sayısal Yükseklik Modelleri içeren uydu görüntülerini temel alarak İHA'nın konumlandırılmasını gerçekleştirmekte, bu süreçte Evrişimli Sinir Ağları kullanılarak İHA ve uydu görüntüsü arasındaki farklar analiz edilmektedir. Bu analiz, iki görüntü arasındaki ilişkiyi derinlemesine inceleyerek daha stabil bir kayıt elde etmeyi amaçlamaktadır. Konumlandırma yönteminin doğruluğunu ve güvenilirliğini artırmak için, gruplandırılmış paket ayarlama (Bundle Adjustment- BA) temelli bir yerel optimizasyon yöntemi önerilmiştir. Gerçekleştirilen deneyler, İHA'nın göreceli yüksekliği 0.5km olduğunda, metodun farklı yörüngelerde ortalama konumlandırma hatasını 15 metreye kadar düşürebildiğini göstermiştir. Bu çalışma, İHA'ların bilinmeyen ve karmaşık ortamlarda otonom navigasyon kabiliyetlerini geliştirmek adına önemli bir katkı olarak değerlendirilmektedir (Hou vd., 2021).

He, Nabil ve Song (2021), özellikle sınırlı hesaplama kaynaklarına sahip küçük İnsansız Hava Araçları için bilinmeyen karmaşık bir ortamda otonom navigasyonun zorluklarını ele alır. Bu çalışmada, yazarlar, bir dört pervaneli İHA'nın bilinmeyen dış mekân ortamında otonom olarak uçabilmesi için sinir ağı tabanlı reaktif bir denetleyici önerirler. Bu denetleyici, herhangi bir optimizasyon veya yapılandırma alanı araması olmadan sadece mevcut sensör verilerini kullanarak kontrol sinyalinin oluşturur. Bu yaklaşım hem bellek hem de hesaplama gereksinimlerini azaltır. Yazarlar, navigasyon problemini bir Markov Karar Süreci (MDP) (Howard, 1970) olarak modellemiş

ve derin pekiştirmeli öğrenme (DRL) yöntemi kullanarak çözmüşlerdir. Ayrıca, eğitilmiş ağı daha iyi anlamak için bazı model açıklama yöntemleri önermişlerdir. Bu çalışma, İHA'ların bilinmeyen ve karmaşık ortamlarda otonom navigasyon yeteneklerini geliştirmek için önemli bir kaynak olarak değerlendirilebilir (He vd., 2021) .

Mughal, Khokhar ve Shahzad'ın “Assisting UAV Localization Via Deep Contextual Image Matching” başlıklı çalışması, GPS sinyalinin bozulduğu veya kesintiye uğradığı durumlarda İHA'ların yerini belirlemek için modern ve yenilikçi derin öğrenme tekniklerini kullanmaktadır (Mughal vd., 2021). Bu çalışma, uçak kameraları ve önceden kaydedilmiş coğrafi olarak referanslanmış görüntülerle, İHA'ların yerini belirlemek için derin öğrenme modellerini ve gelişmiş görüntü işleme tekniklerini kullanır. Mughal ve arkadaşlarının araştırmasına benzer şekilde, bu çalışmada da yeni nesil derin sinir ağları ve gelişmiş görüntü analizi teknikleri kullanılarak İHA navigasyonu için geliştirilmiş çözümler sunulmaktadır. Her iki çalışma da karmaşık çevresel koşullarda ve dinamik engellerle başa çıkmak için derin öğrenme tabanlı yöntemlerin potansiyelini göstermektedir. Ancak, bu çalışmadaki yaklaşım, Mughal ve arkadaşlarının çalışmasında sunulan yöntemlerin ötesinde, belirli zorluklar ve senaryolar için özelleştirilmiş çözümleri ele almaktadır.

Braga ve arkadaşlarının yaptığı çalışmada, insansız hava araçları (İHA'lar) için entegre bir navigasyon sistemi sunulmaktadır(Braga vd., 2016). Yazarlar, bu sistemi, coğrafi referanslı uydu veya hava görüntüleri kullanarak, GPS arızası durumunda İHA'nın navigasyon sistemini desteklemeyi amaçlayan bir yaklaşım olarak tanımlamaktadırlar. Bu entegre sistem, ataletsel sensörler, görsel odometre ve İHA'nın yüksek çözünürlüklü video kaydını birleştiren bir yapıya sahiptir. Geliştirdikleri görüntü eşleme tabanlı yaklaşım, özellik çıkarımı, eşleştirme ve kayıt aşamalarını içermekte ve bu aşamalar, görüntülerin coğrafi referansları ile İHA'nın video kaydını eşleştirmek için kullanılmaktadır. Yapılan deneylerde, bu entegre navigasyon sisteminin, gerçek uçuş verileri üzerinde etkili bir şekilde çalıştığı ve düşük irtifada bile doğru konum bilgileri sağlayabildiği gösterilmiştir. Yazarlar ayrıca, bu bilgilerin İHA'nın durum tahmininin sapmasını otomatik olarak telafi etmek için kullanılabileceğini belirtmektedirler.

Xu ve arkadaşlarının 2023 yılındaki araştırması, GPS ve iletişim engellenmiş ortamlarda birden fazla insansız hava aracının koordineli bir biçimde yol planlaması için yenilikçi bir çözüm sunar (Xu vd., 2023). Bu çalışmada, Derin Pekiştirmeli Öğrenme 'ye dayanan Özellik Füzyon Yakınlık Politikası Optimizasyonu (FF-PPO) algoritması tanıtılmaktadır. FF-PPO, görüntü tanıma bilgilerini ve orijinal görüntüyü entegre ederek, hedef konumun koordinatlarının belirsiz olduğu ortamlarda etkin yol planlaması gerçekleştirir. Bu algoritma, çoklu İHALAR arasındaki iletişimin engellendiği durumlar için bağımsız bir protokol sağlayarak, dağıtık kontrol mekanizmalarıyla İHALARIN kooperatif görevlerini destekler. Araştırma, algoritmanın simülasyonlar ve gerçek dünya testleriyle etkinliğini ve uygulanabilirliğini detaylı bir şekilde inceler. Bu yaklaşım, karmaşık ve belirsiz ortamlarda çoklu İHA'lar için yol planlaması konusunda önemli bir katkı sunmakta ve

gelecekteki arařtırmalar için bir temel oluřturmaktadır. Bu tür yenilikçi yaklařımlar, İHA teknolojisinin geliřiminde ve zorlu ortamlarda kullanımında önemli rol oynamaktadır.

Cesetti ve arkadaşlarının 2011 tarihli çalışması, İHA'lar için GPS yerine görsel işaretleri kullanarak konum belirlemeyi önerir. Bu çalışma, doğal işaretleri izleyen bir algoritma kullanarak ve SIFT (Scale-Invariant Feature Transform) özellik çıkarıcı ile RANSAC (Random Sample Consensus) filtreleme tekniklerini kullanarak İHA'nın konumunu ve yüksekliğini hesaplar (Cesetti vd., 2011). Bu yöntem, GPS sinyallerinin güvenilirmez olduđu durumlar için alternatif bir çözüm sunmaktadır. Ancak, Cesetti ve arkadaşlarının önerdiđi yöntemlerin aksine bu çalışma kapsamındaki yaklařımlar, daha modern geliřmiş görüntü işleme ve derin öğrenme tekniklerini içerir. Bu teknikler, karmařık çevresel durumlar ve beklenmedik engellerle baş etmede daha iyi performans göstererek İHA navigasyonunu daha da geliřtirmeyi amaçlamaktadır.

Lee ve arkadaşlarının 2013 yılındaki çalışması, "Vision-based Terrain Referenced Navigation for Unmanned Aerial Vehicles using Homography Relationship" başlıđı altında, insansız hava araçları için görsel tabanlı araziye dayalı navigasyon sistemlerinin geliřtirilmesi üzerine yoğunlařmaktadır. Bu çalışma, özellikle GPS'in kullanılmadıđı durumlar için alternatif bir yöntem olarak ön plana çıkmaktadır. Arařtırmacılar, İHA'ların hedef takibi ve konum tespiti için görsel bilgileri nasıl işleyebileceđini ayrıntılı olarak ele alırlar. Çalışma, düz ve engebeli araziler üzerinde yapılan deneylerle, görüntü tabanlı ve araziye dayalı navigasyon sistemlerinin hata oranlarını, saf ataletsel navigasyon sistemleriyle kıyaslamaktadır. Bu karřılařtırma, İHA navigasyon sistemlerinin geliřtirilmesi için önemli bulgular sunmaktadır (Lee vd., 2013).

Bu inceleme makalesinde ise, Ali vd., 2022), insansız hava araçları için dış mekan navigasyon algoritmalarını bilgisayar görüş sistemlerine dayalı olarak ele almaktadırlar. Yazarlar, özellikle GNSS sinyali alınamayan ortamlarda, optik aralık kameraları kullanılarak gerekleřtirilen algoritmalar üzerine odaklanmıřlardır. Optik aralık kameraların kullanımı, görüntülerin derinliđini ölçmek için kullanılır, böylece uydu sinyallerinin zayıf veya engellendiđi durumlarda bile dođru navigasyon sađlanabilir (Oggier vd., 2004). Çeřitli algoritmalar ve teknikler ayrıntılı olarak incelenmiř, avantajları ve dezavantajları tartıřılmıřtır. Bu çalışma, gelecekte bu alanda daha fazla arařtırma ve geliřtirme yapılmasının gerekliliđini vurgulamaktadır, ayrıca mevcut teknolojinin hangi durumlar için en uygun olduđuna dair deđerli bir analiz sunmaktadır.

Hu ve arkadaşlarının 2011 yılında gerekleřtirdikleri çalışma, ataletsel navigasyon sistemleri için řablon eřleřtirme yoluyla nesne tespiti konusuna odaklanmaktadır. Arařtırmada, uçan araçların yer nesnelerini tespit etme ve takip etme yeteneklerini artırmak için matematiksel morfolojik řablon eřleřtirme tekniđi önerilmiřtir. Bu yöntemin etkinliđi, Matlab kullanılarak farklı yükseklik ve açılarda gerekleřtirilen simölasyonlarla test edilmiřtir, sonuçlar ise teknolojinin nesne tanıma kapasitesindeki başarısını göstermektedir (Hu vd., 2011).

Bu çalışmanın önemi, belirli bir teknolojik döneme ait olması ve o dönemdeki teknik sınırlamaları yansıtmasıdır. Yapay zekâ ve derin öğrenme alanlarındaki hızlı geliřmeler göz önünde


bulundurulduğunda, bu çalışmanın yöntemleri ve bulguları artık çağdaş standartlara göre eskimiş sayılabilir. Bu nedenle, güncel teknolojik gelişmeler ve yenilikler ışığında, metodolojinin ve sonuçların gözden geçirilmesi gerekmektedir. Bu tür çalışmalar, teknolojinin ilerlemesiyle nasıl evrildiğini göstermesi açısından önemlidir.

Kwak ve Sung'un 2019 tarihli çalışmasında, İHA'lar için otomatik uçuş yön noktalarını belirleme konusu ele alınırken, bu araştırmanın metodolojisi ve amacı, bu tez çalışmasından önemli ölçüde farklılık göstermektedir (Kwak & Sung, 2019). Kwak ve Sung, otokodlayıcı kullanarak İHA'ların engellere çarpmadan uçuş güzergahlarını otomatik olarak belirleyen bir sistem önermektedirler. Bu sistem, pilot müdahalesinin azaltılmasına ve navigasyon hatalarının minimize edilmesine odaklanmaktadır. Öte yandan, Kwak ve Sung'un yaklaşımının aksine bu tez çalışması, nadir görüntülerin işlenmesine yönelik olup, bu tür görüntülerin özgün zorluklarını ve bu zorlukların üstesinden gelme yöntemlerini detaylandırmaktadır. Nadir görüntülerin işlenmesi, özellikle değişken çevresel koşullar ve karmaşık görsel yapılar göz önünde bulundurulduğunda, İHA navigasyonu için kritik öneme sahiptir. Araştırma hedefleri ve yöntemleri açısından farklılık, İHA teknolojisi ve görsel navigasyon alanındaki çeşitliliği ve derinliği göstermektedir.

3. MATERYAL VE METOT

3.1. Materyal

Bu çalışma kapsamında ihtiyaç duyulan teknolojik ekipmanlar ve malzemeler, üniversitemizin Bilimsel Araştırma Projeleri Birimi tarafından sağlanan finansal desteğin bir parçası olarak temin edilmiştir. Bu ekipmanlar arasında, derin öğrenme işlemleri ve simülasyonlar için özel olarak kullanılmış yüksek bellek ve işlem gücü kapasiteli bir grafik işlem birimi (GPU), NVIDIA RTX 3060 12 GB bulunmaktadır. Bu grafik kartı, büyük veri setleri üzerinde karmaşık derin öğrenme algoritmalarını ve simülasyonları etkili bir şekilde gerçekleştirmek için gerekli işlem gücünü ve bellek kapasitesini sağlamaktadır. Ayrıca, çalışmada geliştirilen navigasyon metodolojilerinin denemeleri için kullanılacak olan İnsansız Hava Aracı'nın işlem kapasitesini desteklemektedir. İHA'nın donanımı, yüksek çözünürlüklü bir kamera ve gelişmiş bir uçuş kontrol kartına sahip olup, gerçek zamanlı görüntü işleme kapasitesine kavuşturur. Uçuş kontrol kartı, İHA'nın IMU, barometre ve manyetik yön bulma sensörü gibi sensörlerden aldığı verileri hızlı bir şekilde işleyerek uçuş kontrol elemanlarına anında komutlar verecek kapasitede tasarlanmıştır. Kamera, en az 8 megapiksel çözünürlüğe ve düşük ışık koşullarında dahi saniyede en az 10 kare (frame) kaydedebilme yeteneğine sahiptir. Materyal toplama, eğitim ve test sürecinin akış şeması Şekil 3.1 'de verilmiştir.



Şekil 3.1. Genel Akış Şeması

3.1.1. Sinir Ağı İçin Eğitim Verisi toplama- Uydu Verileri ve Haritalar

Bu çalışmada, İnsansız Hava Araçları (İHA) tarafından elde edilen görüntüler ve Google haritalar ve uydu verilerinden oluşturulan ortofoto haritaları esas alınmıştır. Araştırmanın temelini, evrişimli otokodlayıcı (Convolutional Autoencoder-CAE) sinir ağı mimarisi kullanılarak geliştirilen bir Derin Öğrenme metodolojisi oluşturmaktadır (LeCun vd., 1995). Bu bağlamda, iki temel veri seti hazırlanmıştır: Birincisi, uydu görüntüsü verileri, ikincisi ise bu uydu görüntülerinin jeokoordinatlarına karşılık gelen soyut öznitelik harita verileridir.

Veri toplama sürecinde, Google Maps API kullanılarak belirlenen şehir koordinatlarından uydu görüntüleri elde edilmiştir. Bu süreçte, Python programlama dili ile geliştirilen bir betik

kullanılarak toplamda 406.579 adet uydu ve harita görüntüsü toplanmıştır. Elde edilen görüntüler, iki farklı uzamsal çözünürlükte (0,298 ve 0,596 metre) ve 544x544 piksel boyutlarında, aynı jeokoordinatlara karşılık gelen harita görüntüleri olarak eğitim verisi yapılmıştır. 544x544 boyutunun seçilmesi ileride detaylandıracağı üzere istenilen detay seviyesi ve sınır ağı mimarisi gereğidir.

Çizelge 3.1’de araştırmada kullanılan verilerin coğrafi menşei detaylandırılmaktadır. Şekil 3.’deki dünya haritası, eğitim görüntüleri elde edilen şehirlerin Çizelge 3.1’de verilen koordinatlarının coğrafi konumlarını belirtmektedir. Bu çizelge ve şekil, araştırma sürecinde veri olarak ele alınan yerleşim alanlarının kapsamını ve yer seçimini ortaya koyar.

Kuzey-Güney Y: Enlem (latitude) olarak adlandırılır ve dünya üzerinde kuzey-güney doğrultusundaki konumu belirtir. Ekvator, 0° enlem olarak kabul edilir. Kuzey yarım küredeki konumlar pozitif (+), güney yarım küredeki konumlar ise negatif (-) olarak gösterilir.

Doğu-Batı X: Boylam (longitude) olarak adlandırılır ve dünya üzerinde doğu-batı doğrultusundaki konumu belirtir. Başlangıç meridyeni (Greenwich Meridyeni), 0° boylam olarak kabul edilir. Doğu yönündeki konumlar pozitif (+), batı yönündeki konumlar ise negatif (-) olarak gösterilir.

Bu çalışmada toplanan veri örnekleri, belirlenen iki koordinat noktası arasındaki bölgeden rastgele seçilmiştir: Bir nokta şehrin sol üst bölgesini temsil ederken, diğer nokta sağ alt bölgesini temsil etmektedir. Örneğin, Adana için belirtilen koordinatlar sol üstte 37.052607° Kuzey enlem ve 35.226253° Doğu boylam iken, sağ altta 36.968963° Kuzey enlem ve 35.394458° Doğu boylam olarak ifade edilmiştir. Bu, Adana’nın coğrafi sınırları içerisindeki iki farklı noktayı tanımlar ve veri toplama sürecinin coğrafi çerçevesini belirler.

Öte yandan, Şekil 3.’de seçilen bu şehirlerin dünya haritası üzerindeki yerlerini görselleştirerek, veri toplama faaliyetimizin coğrafi yayılımını somut bir biçimde gösterir. Şekil 3. ise, bu şehirlerden elde edilen uydu görüntülerinin örneklerini sunarak, kullanılan veri türünün niteliksel özelliklerini sergiler.



Şekil 3.2 Görüntü örneklerinin alındığı şehirlerin harita üzerindeki konumları

Çizelge 3.1. Eğitim Verisi Olarak Seçilen Şehirlerin Koordinatları

Şehir	Sol üst		Sağ Alt	
	Kuzey-Güney Y	Doğu-Batı X	Kuzey-Güney Y	Doğu-Batı X
"Adana"	37.052607	35.226253	36.968963	35.394458
"Alanya"	36.557751	31.983474	36.543669	32.022251
"Ankara"	39.992547	32.699055	39.875204	32.921451
"Antalya"	36.888268	30.669107	36.942196	30.762163
"Atina"	38.051558	23.814942	37.943849	23.620924
"Austin"	30.458142	-97.930564	30.215759	-97.609214
"Barcelona"	41.359346	2.093876	41.439256	2.187270
"Basel"	47.521211	7.592835	47.576944	7.661728
"Berlin"	52.607274	13.184707	52.391336	13.731834
"Bern"	46.994806	7.365678	46.902323	7.524771
"Biel/Bienne"	46.952452	7.423724	47.006153	7.476498
"Birmingham"	52.518535	-1.939266	52.380062	-1.728041
"Bordeaux"	44.866349	-0.645993	44.780956	-0.527435
"Boston"	42.453045	-71.271380	42.256673	-70.985049
"Bremen"	53.076179	8.686603	53.194313	8.925233
"Bursa"	40.247862	28.856216	40.180010	29.211576
"Bydgoszcz"	53.178161	18.544303	53.051953	18.726835
"Castlebar"	53.847081	-9.328021	53.784160	-9.135712
"Cavan"	53.727398	-7.825945	53.672162	-7.648753
"Cenevre"	46.193967	6.124707	46.239656	6.166062
"Charlotte"	35.311287	-80.975792	35.068867	-80.693581
"Chicago"	42.227976	-88.438174	41.544679	-87.482732
"Columbus"	40.132650	-83.174170	39.851734	-82.786216
"Cork"	51.920876	-8.570748	51.848403	-8.366206
"Dallas"	33.055706	-97.185433	32.663494	-96.610711

Çizelge 3.1'in devamı

"Denver"	39.930841	-105.207368	39.566041	-104.780274
"Dublin"	53.430300	-6.389492	53.286382	-6.100792
"Duisburg"	51.224167	6.746915	51.341822	6.936576
"Düsseldorf"	51.439332	6.775668	51.360662	7.030409
"Ennis"	52.854726	-9.429423	52.788285	-9.253422
"Eskisehir"	39.814458	30.486188	39.741508	30.581231
"Espoo"	60.995380	24.297370	60.921190	24.580034
"Essen"	51.460047	7.324389	51.543726	7.484491
"Fort Worth"	33.216238	-97.491224	32.549658	-96.978987
"Frankfurt"	50.111958	8.489831	50.023231	8.809639
"Galway"	53.292535	-9.111254	53.238165	-8.952142
"Gaziantep"	37.107040	37.300213	37.007327	37.441821
"Gdańsk"	54.449578	18.357814	54.263289	18.837758
"Gloucester"	51.785842	-2.273026	51.722930	-2.150585
"Göteborg"	57.822876	11.891240	57.620668	12.072295
"Halmstad"	57.163019	12.241902	57.094716	12.336423
"Hamburg"	53.674541	9.748841	53.381156	10.245433
"Hannover"	52.345583	9.625253	52.423431	9.847081
"Hatay"	36.242853	36.120060	36.193125	36.168129
"Heilbron"	49.159528	9.178179	49.126738	9.223669
"Helsinki"	60.297532	24.815861	60.098502	25.263396
"Houston"	30.033499	-95.715808	29.459993	-94.920672
"Indianapolis"	39.922557	-86.312658	39.641834	-85.952169
"istanbul_1"	41.151558	28.742022	41.001397	28.983243
"istanbul_2"	41.100909	28.959289	40.999812	29.113099
"istanbul_3"	41.029682	29.132382	40.875418	29.358901
"İzmir"	38.497551	27.077615	38.368000	27.193171
"Jacksonville"	30.514245	-81.869883	30.186570	-81.442789
"Jönköping"	57.760791	14.142889	57.679194	14.270987
"Karlstad"	59.369086	13.788001	59.305343	13.901293
"Katowice"	50.081969	19.877164	49.951573	20.049798
"Kayseri"	38.758188	35.409117	38.685072	35.563654
"Konya"	37.961300	32.434965	37.807296	32.549372
"Köln"	50.938634	6.824169	50.853886	6.986364
"Krakow"	50.185172	19.882874	49.938773	20.195808
"Kuopio"	62.936196	27.428858	62.861688	27.823246
"Lahti"	61.819928	24.705972	61.756742	25.006854
"Leeds"	53.827707	-1.672900	53.743679	-1.444008
"Lille"	50.740455	3.095982	50.630083	3.194843
"Limerick"	52.696697	-8.894635	52.621737	-8.734685
"Linköping"	58.431413	15.141404	58.363727	15.259755
"Liverpool"	53.431383	-3.069995	53.334223	-2.891335


Çizelge 3.1'in devamı

"Londra"	51.592004	-0.387763	51.343994	-0.006621
"Los Angeles"	34.271847	-118.612484	33.767620	-117.787487
"Lozan"	46.520127	6.632035	46.560849	6.681518
"Lublin"	51.294761	22.545235	51.157389	22.696249
"Lugano"	47.136064	8.433222	47.198343	8.517330
"Luzern"	47.364930	9.663109	47.404064	9.704559
"Lyon"	45.809011	4.763332	45.707716	4.898327
"Malmö"	55.643201	12.913925	55.533277	13.037231
"Manchester"	53.495595	-2.362580	53.345904	-2.145966
"Marseille"	43.320643	5.284834	43.222683	5.532311
"Mersin"	36.824951	34.512529	36.781712	34.609816
"Münih"	48.064952	11.413219	48.248015	11.714173
"Nantes"	47.351238	-1.670146	47.187002	-1.471962
"Nevşehir"	38.638091	34.694545	38.619486	34.725007
"New York"	40.991405	-74.365583	40.583818	-73.603406
"Nice"	43.640420	7.208878	43.569070	7.293808
"Norrköping"	58.544080	15.990895	58.472504	16.088993
"Osmaniye"	37.058660	36.219422	37.091119	36.288773
"Oulu"	65.041741	25.289059	64.963413	25.629689
"Paris"	48.898696	2.272479	48.814645	2.397223
"Peterborough"	52.657132	-1.205164	52.581713	-0.997498
"Pheonix"	33.855222	-112.405234	33.298023	-111.733694
"Philly"	40.138507	-75.373468	39.887653	-74.993753
"Pori"	61.243281	21.424444	61.180884	21.816030
"Portlaoise"	53.105238	-7.934426	53.048508	-7.754448
"Rennes"	48.121433	-1.736805	48.073518	-1.607648
"Sakarya"	40.792451	30.340400	40.716307	30.417986
"Salo"	60.510978	22.761262	60.431241	23.068768
"San Antonio"	29.631655	-98.732791	29.233372	-98.241152
"San Diego"	32.930348	-117.268312	32.634778	-116.942842
"San Francisco"	37.803824	-122.511415	37.711401	-122.382325
"San Jose"	37.423943	-122.109931	37.223002	-121.756309
"Seattle"	47.732233	-122.418975	47.508225	-122.252120
"Selanik"	40.692616	22.906257	40.638100	22.955584
"Sheffield"	53.416143	-1.571719	53.316131	-1.344840
"Sligo"	54.281139	-8.619942	54.221540	-8.431697
"Sosnowiec"	50.107563	18.918465	50.024886	19.139242
"Southampton"	50.955134	-1.481832	50.879114	-1.305397
"St. Gallen"	47.041870	9.294784	47.094448	9.369950
"Stockholm"	59.437702	17.758697	59.225682	18.238883
"Stuttgart"	48.746662	9.132390	48.812970	9.225490
"Szczecin"	53.852638	14.549062	53.780262	14.881231

Çizelge 3.1'in devamı

"Tampere"	61.503878	23.535625	61.413243	23.899547
"Toulouse"	43.635268	1.341776	43.561619	1.468986
"Tours"	47.478525	0.664707	47.384097	0.757362
"Turku"	60.439718	22.077919	60.368997	22.400348
"Uppsala"	59.879518	17.495869	59.823151	17.656060
"Urgup"	38.641115	34.900458	38.622930	34.939553
"Vantaa"	60.235416	24.662841	60.161228	24.950231
"Varşova"	52.279914	20.926606	52.096664	21.275537
"Växjö"	56.887782	14.747046	56.804931	14.832267
"Washington DC"	38.997979	-77.224005	38.794638	-76.894415
"Waterford"	52.273097	-7.159928	52.216705	-6.973963
"Winterthur"	47.693447	8.635288	47.745943	8.702424
"Wrocław"	51.179779	16.964441	51.013739	17.243341
"York"	54.011999	-1.590985	53.922272	-1.351721
"Zielona Góra"	51.985276	15.834148	51.877688	16.151238
"Zürich"	47.376607	8.523982	47.418344	8.622428

a) Bern



b) Houston



c) san jose



d) Lyon



Şekil 3.3 Bazı Şehirlerin eğitim için kullanılan görüntü örnekleri sol taraf uydu görüntüsü sağ taraf aynı jeokoordinata karşılık gelen Google maps görüntüsü


3.1.2. Testlerde Kullanılacak Haritanın Temini

Test sürecinde konum tespiti için kullanılan haritanın uzamsal çözünürlüğü, sonuçların doğruluğu üzerinde kritik bir etkiye sahiptir. Yürütülen ön çalışmalarda, 0.298 metre uzamsal çözünürlüğe sahip haritaların konum tayininde daha isabetli sonuçlar sunduğu belirlenmiştir. Bu nedenle, tüm testler bu çözünürlükte gerçekleştirilmiştir.


Başlangıçta Google Maps ve Bing Maps üzerinden şehir alanları ve arazi alanları harita verileri temin edilmiştir (Şekil 3.a, Şekil 3.c). İlgili bölgenin Google maps dahilinde 19. Seviye yakınlaştırması(Stefanakis, 2017) olan 0.298 metre uzamsal çözünürlükteki haritasını elde etmek amacıyla Google Maps api kullanılarak Python programlama dilinde özel bir kod yazılmıştır. Bu

kod, belirlenen jeokoordinatlara göre harita verisini çekmek için kullanılmıştır. Otokodlayıcı Sinir ağı modelinin haritaya uygulanması için 544x544'lük kenarlarından 32 pikseli örtüşecek şekilde parçalara bölünmesi gerekir. Zira mevcut algoritmalar ve donanım kısıtı bunu gerektirmektedir. Her bir parçaya sinir ağı uygulandıktan sonra dört tarafından 16 piksel kırılarak 512x512'lik parçalar elde edilir. Bu parçalar birleştirilerek sinir ağı uygulanmış büyük harita elde edilir. Daha sonra bu harita coğrafi olarak referanslanır. Coğrafi referans olarak WGS 1984 UTM Zone 36N - EPSG:32636 (Decker, 1986) seçilmiştir.

Gerçekleştirilen testlerde kritik bir konu doğru irtifa tahminidir. Bu kapsamda, şehir ve arazi alanlarına ait koordinatlar dikkate alınarak, Avrupa Uzay Ajansı (ESA) tarafından geliştirilen Sentinel Application Platform (SNAP) yazılımı ve bu yazılımın DEM Tools modülü, 30 metre uzamsal çözünürlüğe sahip sayısal yükseklik modeli (SYM) verilerinin elde edilmesinde kullanılmıştır (*ESA-Sentinel Application Platform (SNAP), Copernicus Data, 2023*). Elde edilen SYM haritaları, jeoreferanslandırılarak Şekil 3.b d 'de gösterilmiştir.




a) Şehir alanları testlerinin gerçekleştirildiği harita



b) Şehir alanları Sayısal Yükseklik Modeli Haritası



c) Arazi alanları testlerinin gerçekleştirildiği Harita



d) Arazi alanları Sayısal Yükseklik Modeli Haritası

Şekil 3.4. a) Otokodlayıcı Sinir ağı modelinin uygulanacağı şehir haritası b) şehir haritasıyla aynı koordinatların sayısal yükseklik modeli haritası c) Otokodlayıcı sinir ağı modelinin uygulanacağı arazi haritası d) arazi haritasıyla aynı koordinatların sayısal yükseklik modeli haritası

Coğrafi Referans Sistemi Seçimi

İnsansız Hava Aracı (İHA) tabanlı görsel navigasyon sistemlerinin temel bir gerekliliği, yer yüzeyini yüksek doğrulukla ve tutarlı bir şekilde temsil etme yeteneğidir. Bu çalışmada, görsel navigasyon için şablon eşleme yöntemini uygularken, Coğrafi Referans Sistemi (CRS) olarak WGS

1984 UTM Zone 36N - EPSG:32636 (*The European Petroleum Survey*, 2023) projeksiyonu tercih edilmiştir. Bu seçim, aşağıda detaylandırılan bir dizi kritik faktöre dayanmaktadır:

Yüksek Yerel Doğruluk

UTM (Universal Transverse Mercator) projeksiyonu, yerel ve bölgesel ölçekte yüksek doğruluk sağlar. Bölgesel ölçekte yapılan mesafe ve alan ölçümlerinde distorsiyonu minimize eder, bu da İHA'nın alçak irtifa uçuşlarında ve küçük ölçekli alanlarda uçuş yaparken hassas konumlandırma gereksinimleri için idealdir.

Doğrusal Ölçüm Kolaylığı

Projeksiyonun düzlem doğasından dolayı, UTM koordinatları ile doğrusal ölçümler basit ve doğrudan hesaplanabilir. Bu, görüntüler üzerindeki piksel tabanlı ölçümlerin yeryüzündeki gerçek mesafelere dönüştürülmesinde önemli bir avantaj sağlar.

Eş Ölçeklilik

UTM Zone 36N'nin ölçek faktörü (0.9996), merkez meridyen boyunca neredeyse gerçek boyutlu bir temsil sunar. Bu, İHA'nın şablon eşleme yöntemleriyle uğraşırken, yeryüzündeki nesneler arasındaki göreceli boyutların ve mesafelerin tutarlı kalmasını sağlar.

Küresel ve Yerel Veri Entegrasyonu

WGS 1984 datumu, küresel konumlandırma sistemleri (GPS) ile uyumludur ve geniş çapta kabul görmüş bir standarttır. Bu, yerel olarak toplanan verilerin küresel veri kümeleriyle entegrasyonunu kolaylaştırır ve böylece İHA'nın navigasyon sistemini uluslararası platformlarla uyumlu hale getirir.

Uzamsal Çözünürlük Hesaplama doğruluğu

Araştırmanın temel odak noktalarından biri, İHA'nın elde ettiği görüntülerin Uzamsal Çözünürlüğün (Ground Sample Distance- GSD) doğru bir şekilde hesaplanmasıdır. Uzamsal Çözünürlük, yeryüzündeki bir pikselin temsil ettiği gerçek mesafeyi ifade eder ve görüntü analizinin doğruluğu için kritik bir metriktir. UTM projeksiyonunun düzlem tabanlı doğrusal ölçüm kabiliyeti, uzamsal çözünürlüğün hassas bir şekilde hesaplanmasını ve böylece İHA'nın görsel navigasyon sisteminin güvenilirliğini artırır. Bu, özellikle şablon eşleme algoritmalarının başarı oranını etkiler ve gerçek dünya koşullarında navigasyonun doğruluğunu önemli ölçüde iyileştirir.

Bu çalışmada, İHA'nın nadir görüntülerinin işlenmesi ve görsel navigasyon sırasında yüksek doğruluk ve tutarlılık elde etmek için WGS 1984 UTM Zone 36N'nin seçilmesi stratejik bir karardır. Bu CRS, yerel coğrafi koşullara özgü detayların doğru bir şekilde haritalanmasını ve yüksek uzamsal

öz n rl ge sahip g r nt lerin etkin bir biimde coğrafi olarak konumlandırılmasını m mk n kılar. Bu,  zellikle g r nt  tabanlı řablon eřleme algoritmalarının hassasiyetini ve etkinliğini artırarak, İHA'nın gerek d nya kořullarında doėru navigasyon yeteneklerini geliřtirir. Dolayısıyla, WGS 1984 UTM Zone 36N'nin kullanımı, bu arařtırmanın y ntemsel yaklařımının temel bir parası olarak hem teorik hem de pratik sonuların g venilirliğini ve doėruluėunu  nemli  l de artırır.

3.1.3. Uuř Test verisi

Bu alıřmada, DJI Mavic 2 Pro İHA kullanılarak elde edilen ve 5472×3648 piksel  z n rl ė nde RGB formatında olan 2953 nadir g r nt  test verisi olarak kullanılmıřtır. Bu g r nt ler, 11 farklı g zergahta, řehir alanları ve aık araziler  zerinde, her bir g zerg h iin yaklařık 2 saniye aralıklarla kaydedilmiřtir. G r nt lerde GPS verisi ile ataletsel  l m birimi'nden (Inertial Measurement Unit-IMU) gelen y n verisi de exif bilgisi ve metadata olarak bulunmaktadır.

Test verisi seti hem řehir alanlarında hem de aık arazilerde elde edilmiř g r nt lerden oluřmasındaki sebep, modelin farklı ortamlara adaptasyon kabiliyetini test etmek ve genelleme yeteneğini deėerlendirmek iin  nemlidir. Ayrıca, yaklařık her iki saniyede bir alınan g r nt ler, İHA'nın teknik kısıtlamaları g z  n nde bulundurularak seilmiřtir. DJI Mavic 2 Pro'nun maksimum hızı ve y ksekliėi gibi operasyonel sınırlar, veri toplama sırasında g r nt  kalitesini ve s rekliliğini etkilemektedir. Bu zaman aralıėı, İHA'nın bu kısıtlamalar iinde verimli bir řekilde alıřmasını saėlayarak, farklı hız ve y ksekliklerdeki performansının deėerlendirilmesine olanak tanımaktadır. B ylece, modelin gerek d nya kořullarındaki uygulanabilirliėi ve eřitli operasyonel senaryolarda ne kadar etkili olduėu daha iyi anlařılmaktadır.

İHA: DJI MAVIC 2 Pro

Bu alıřmada kullanılan DJI Mavic 2 Pro İHA (řekil 3.) y ksek  z n rl kl  g r nt leme ve hassas konumlandırma yetenekleriyle  ne ıkmaktadır (*DJI Mavic 2 Product Information*, 2018). İHA'nın temel  zellikleri, 5472×3648 piksel  z n rl ė nde RGB formatında g r nt ler elde etme kabiliyeti ve GPS ile IMU'dan gelen y n verilerini ieren EXIF metadata bilgilerine sahip olmasıdır. Bu teknik  zellikler, arařtırmanın gereksinimlerine uygun detaylı ve doėru konumlandırılmıř veri toplama imk n  sunmaktadır.



Şekil 3.5. DJI Mavic 2 Pro İnsansız Hava Aracı

İHA'nın yatay konumlandırma doğruluğu teorik olarak ± 1.5 metre, dikey konumlandırma doğruluğu ise ± 0.5 metre olarak belirtilmiştir. Ancak, gerçek dünya uygulamalarında yapılan testlerimizde, GPS tabanlı konumlandırmanın yaklaşık ± 10 ila ± 15 metre arasında bir hata payı ile çalıştığı gözlemlenmiştir. Bu artan hata payı, özellikle GPS sinyallerinin zayıf olduğu veya çevresel etkilerin yoğun olduğu durumlarda daha belirgindir. Bu durum, uçuş yolunun doğru bir biçimde kaydedilmesi ve elde edilen görüntülerin jeo-etiketlenmesinde dikkate alınmalıdır, zira bu faktörler veri setinin uzamsal doğruluğunu önemli ölçüde etkileyebilir.

İHA'nın üç eksenli gimbal sistemi, kameranın nadir görüntü alırken sabit bir noktaya odaklanmasını kontrol eder ve böylece hareketli uçuş sırasında bile yüksek kaliteli görüntüler elde edilmesini sağlar. Kameranın 10.26 mm (35 mm eşdeğeri 28 mm) odak uzunluğu ve 77 derecelik görüş alanı, geniş bir alanda detaylı görsel veri toplama imkânı sunar. Kamera sistemi, Zhang tarafından tanıtılan tessellasyon kalibrasyon yöntemi kullanılarak kalibre edilmiştir (Zhang, 2000). Bu yöntem, kameranın kalibrasyon matrisini (K) ve lens distorsiyon parametrelerini (D) kullanarak görüntüde oluşan varil distorsiyonunu denklem 1 ve denklem 2'deki parametreleri kullanarak giderir.

- **Kamera Kalibrasyon Matrisi (K):**

$$K = \begin{bmatrix} f_x & s & c_x \\ 0 & f_y & c_y \\ 0 & 0 & 1 \end{bmatrix}$$

$$K = \begin{bmatrix} 4479.94 & -1.91657 & 2727.48 \\ 0 & 4374.51 & 1811.92 \\ 0 & 0 & 1 \end{bmatrix} \quad (3.1)$$

Bu matristeki parametreler şu şekilde yorumlanır:

- $f_x=4479.94$ ve $f_y=4374.51$: İlgili eksenlerde piksel cinsinden odak uzaklıkları, görüntüdeki derinlik algısını ve ölçeklendirmeyi etkiler.
- $c_x=2727.48$ ve $c_y=1811.92$: Görüntü merkezinin (optik merkezin) piksel cinsinden koordinatları.
- $s=-1.91657$: Piksel eksenleri arasındaki çarpıklık faktörü, genellikle sıfıra yakındır ve burada ihmal edilebilir.

• **Lens Distorsiyon Parametreleri (D):**

$$D = \begin{bmatrix} k_1 \\ k_2 \\ p_1 \\ p_2 \\ k_3 \end{bmatrix}$$

Bu durumda:

$$D = \begin{bmatrix} -0.0196948 \\ 0.00652119 \\ 0.000237354 \\ 0 \\ 0.0909295 \end{bmatrix} \quad (3.2)$$

- $k_1=-0.0196948$, $k_2=0.00652119$, ve $k_3=0.000237354$: Radyal distorsiyon katsayıları, merkeze yakın piksellerin düzeltilmesi için kullanılır.
- $p_1=0$ ve $p_2=0.0909295$: Tanjansiyel distorsiyon katsayıları, lensin ve algılama yüzeyinin hizalama hatalarını düzeltir.

Bu kalibrasyon süreci, görüntü kalitesinin iyileştirilmesi ve distorsiyonun azaltılması için önemlidir. Bu sayede, elde edilen görüntülerin analizi daha hassas ve doğru bir şekilde gerçekleştirilebilir.


İHA'nın teknik özellikleri de çalışmanın hedefleriyle uyum içinde etkin bir şekilde kullanılmıştır. GPS ve IMU sistemlerinin hassas entegrasyonu, uçuş sırasında elde edilen görüntülerin doğruluğunu ve kalitesini artırarak, modelin değerlendirilmesi için zengin ve güvenilir bir veri setinin oluşturulmasına katkı sağlamıştır. Üç eksenli gimbal stabilizasyonu ise, hareket halindeyken bile net ve sabit görüntüler elde edilmesini mümkün kılarak, görüntü analizi ve model testleri için ideal koşullar sunmuştur. Bu sistemlerin bir arada kullanılması, araştırmanın karşılaştığı

teknik zorlukların üstesinden gelmeye yardımcı olmuş ve modelin gerçek dünya ortamlarında nasıl performans gösterdiğinin daha etkili bir şekilde değerlendirilmesine olanak tanımıştır.

3.1.4. Test bölgesi


Bu çalışmanın test uçuşları, Türkiye'nin Nevşehir iline bağlı Ürgüp ilçesinde, iki farklı coğrafi bölgede gerçekleştirilmiştir. Ürgüp ilçesi, zengin tarihi dokusu ve doğal güzellikleriyle bilinirken, aynı zamanda İHA testleri için de ideal bir konuma sahiptir. Bu ilçenin seçilmesinin nedenleri arasında, çeşitli coğrafi özellikler, kararlı iklim koşulları ve hava trafiği yoğunluğunun göreceli olarak düşük olması yer almaktadır. Bu faktörler, İHA testlerinin güvenli ve kontrol edilebilir bir ortamda yapılmasını sağlamıştır.

İlk test bölgesi, Ürgüp ilçesinin geniş ve çeşitli arazisini temsil eden bir alanda yer almaktadır. Greenwich meridyenine göre 38.6706° N- 38.6074° N Kuzey enlem ve 28.8706° E- 28.9739° E Doğu boylam aralığında konumlanan bu bölge, yaklaşık 102.50 km^2 'lik bir alanı kapsar (Şekil 3.). Bu bölgenin seçilmesi, İHA'nın şehirsiz çevrelerdeki navigasyon ve görüntüleme kabiliyetlerini etraflıca test etmek ve değerlendirmek içindir. Şehir alanlarının karmaşık yapıları, İHA teknolojisinin çeşitli yapısal ve çevresel engellerle nasıl başa çıktığını gözlemlemek için ideal bir ortam sunar. Bu bölgede gerçekleştirilen test uçuşları, İHA'nın yoğun şehir dokusu içerisindeki performansını detaylı bir şekilde incelemek için stratejik olarak planlanmıştır.



Şekil 3.6 Şehir alanları test bölgesi

İkinci test bölgesi, geniş ve doğal arazi özelliklerine sahip olan, ilçenin başka bir bölümünde yer alır. 38.5947° N- 38.5135° N kuzey enlemleri ve 28.9589° E- 28.0196° E doğu boylamları arasında uzanan bu bölge, yaklaşık 55.36 km^2 'lik bir alanı kapsamaktadır. İHA'nın bu farklı coğrafi koşullarda nasıl performans gösterdiğini gözlemlemek ve değerlendirmek için bu alan özellikle seçilmiştir. İkinci test bölgesinin coğrafi sınırları Şekil 3.'da ayrıntılı bir şekilde sunulmuştur.



Şekil 3.7 Arazi alanları test bölgesi

3.2. Metot

3.2.1. Sinir Ağının Eğitim Süreci

Bu bölüm, insansız hava araçları için geliştirilen görsel navigasyon sistemlerinde kullanılan evrişimli otokodlayıcı sinir ağlarının eğitim süreçlerini kapsamlı bir şekilde ele almaktadır. Araştırmanın bu aşamasında, İHA'ların GPS sinyali zayıf veya mevcut olmayan ortamlarda etkin bir

şekilde konumlarını tespit edebilmelerini sağlamak amacıyla otokodlayıcı tabanlı yöntemlerin uygulanabilirliği ve etkinliği incelenmektedir. Bu süreçte, modelin genel performansını iyileştirmek için sinir ağlarının eğitim verilerinin işlenmesi üzerine detaylı bir inceleme gerçekleştirilmiştir.

Araştırmanın eğitim süreci, özellikle şehir alanlarından elde edilen verilere dayalı olup, bu metodolojinin yapılaşma olmayan alanlarda da uygulanabilirliğinin araştırılması, çalışmanın önemli bir yönünü oluşturmaktadır. Bu çerçevede, modelin genel başarımına olan katkıları ve İHA'ların görsel navigasyon yeteneklerini geliştirmedeki potansiyeli, detaylı bir analitik yaklaşım ile incelenecektir. Ayrıca, modelin gerçek dünya koşullarında uygulanabilirliğini doğrulamak amacıyla yapılan saha testlerinin önemi ve bu testlerin bulguları, bu bölümde kritik bir değerlendirme konusu olacaktır.

Bu bölümün temel amacı, İHA navigasyon sistemleri için otokodlayıcı tabanlı yaklaşımların kullanımını ve bu yaklaşımların çeşitli navigasyon senaryolarında sergilediği performansı derinlemesine değerlendirmektir. İHA'ların görsel navigasyon yeteneklerinin geliştirilmesine yönelik bu yaklaşımların, farklı coğrafi ve operasyonel ortamlarda nasıl uygulanabileceği ve bu uygulamaların potansiyel etkileri, araştırmanın bu aşamasında ele alınan temel konular arasındadır. Bu analiz, ileriye dönük araştırmalar için teorik ve pratik bir temel oluşturmakta ve bu alandaki yeni araştırma yollarını belirlemekte büyük önem taşımaktadır.

Ön işleme

İnsansız hava araçları (İHA) için geliştirilen sinir ağının eğitim sürecinde, eğitim verisinin sağ yarısında yer alan uydu görüntüsü (Şekil 3.), belirli bir dizi ön işleme adımından geçirilmiştir. Ön işleme süreci, görüntülerin karakteristik özelliklerini geliştirerek ve eğitim verilerinden alınan bilgiyi maksimize ederek sinir ağının öğrenme kapasitesini artırmak için kritik öneme sahiptir. Aşağıda, ön işleme sürecinin çeşitli aşamaları ve bunların metodolojik uygulamaları bu çalışma için yazılan bir Python kodu kullanılarak aşağıdaki sırayla uygulanmıştır:

- **Renk Düzeltmeleri:** Görüntülerde renk tonlarının ayarlanması, belirli renk aralıklarını hedef alarak bu renkleri alternatif renklerle değiştirme işlemiyle gerçekleştirilmiştir. Bu süreç, renkler arasındaki kontrastı artırarak, sinir ağının özellik çıkarımını ve sonraki sınıflandırma aşamalarını iyileştirmeyi amaçlamaktadır. Renk tonlarının ayarlanması, modelin algılama kapasitesini ve özellikle düşük kontrastlı bölgelerdeki ayrıntı algılama yeteneğini optimize etmektedir.

- **Bulanıklaştırma:** Görüntülerin kalitesini artırmak ve gürültüyü azaltmak için çift taraflı filtreleme (bilateral filtering) (Paris vd., 2007) tekniği uygulanmıştır. Bu teknik, kenar bütünlüğünü korurken gürültüyü etkili bir şekilde azaltmak için idealdir ve ayrıca görüntülerdeki istenmeyen piksel değişikliklerini yumuşatarak modelin önemli özellikleri daha net bir şekilde algılamasına katkı sağlar.

- **Siyah Beyaz Dönüşümü:** Renk bilgilerinden ziyade doku ve şekil bilgilerine odaklanması için görüntüler, siyah beyaz formata dönüştürülmüştür. Bu adım, modelin renkten bağımsız olarak doku ve şekil özelliklerini daha etkin bir şekilde algılamasına yardımcı olmakta ve özellikle doku analizi ve morfolojik özellik çıkarımında önemlidir.

- **Kontrast Ayarı:** Görüntülerin kontrast ve parlaklık düzeyleri, ayrıntıların daha belirgin hale getirilmesi için ayarlanmıştır. Bu işlem, modelin görüntüdeki ince detayları ve zayıf sinyalleri daha iyi ayırt etmesine imkân tanır. Kontrast ayarlaması, görüntüdeki önemli özelliklerin vurgulanması ve modelin bu özellikleri daha kolay öğrenmesi için kritik bir öneme sahiptir.

Bu ön işleme adımları, eğitim verisinin kalitesini iyileştirerek ve çeşitli özellikleri daha belirgin hale getirerek, sinir ağının eğitim sürecinde daha etkili bir şekilde öğrenmesine katkıda bulunmaktadır. Özellikle, çift taraflı filtreleme ve kontrast ayarı gibi teknikler, veri kalitesini artırırken önemli bilgilerin korunmasını sağlamaktadır. Bu işlemler sonucunda elde edilen görüntüler (Şekil 3.), İHA'ların konumlarını daha doğru bir şekilde belirlemesini sağlamak üzere sinir ağı modelinin eğitim sürecinde kullanılmıştır.

a) Bern



b) Houston



c) San Jose




d) Lyon



Şekil 3.8 Ön işlemden geçirilmiş eğitim verileri a) Bern b) Houston c) San Jose d) Lyon

Derin Sinir Ağları: Uygulamaları ve Mimari Yapısı

Yakın dönemde, yapay sinir ağları, özellikle uzaktan algılama alanında, hızla artan veri miktarlarının işlenmesinde ve analiz edilmesinde kilit bir rol oynamaktadır. Bu veri yoğunluğu, derin sinir ağları gibi gelişmiş yapay sinir ağı modellerinin, daha yüksek doğruluk oranları ve geliştirilmiş öğrenme kapasiteleri ile öne çıkmasına yol açmıştır (Schmidhuber, 2022). DNN'ler, çok katmanlı yapısı (Şekil 3.) ve ağırlıklandırılmış nöron katmanları ile karmaşık veri setlerini işleyebilen ve öğrenebilen bir algoritma çeşididir. Bu algoritmaların temelinde, veriye dayalı ağırlıkların ayarlanmasını sağlayan ileri ve geri yayılım algoritmaları yatar.



Şekil 3.2 Bir Derin Sinir Ağır Mimarisi (Bahi & Batouche, 2018)

Çok katmanlı sinir ağları, genellikle üç ana katmandan oluşur: bir giriş katmanı (input layer), bir veya daha fazla gizli katman (hidden layers) ve bir çıkış katmanı (output layer). Bu yapı, sinir ağlarının karmaşık ve lineer olmayan sınıflandırma görevlerini yerine getirebilmesine olanak tanır. Gizli katmanlarda bulunan nöronların sayısı ve katmanların konfigürasyonu, ele alınan problemin özelliklerine ve karmaşıklığına bağlı olarak değişiklik gösterebilir. Bu esneklik, ağın farklı türdeki veri yapılarına ve problemlere uyum sağlayabilmesini sağlar, böylece daha karmaşık sınıflandırma ve örüntü tanıma işlemleri başarıyla gerçekleştirilebilir.

Modelleme sürecinde, genel bir model oluşturabilmek adına, veri seti tipik olarak eğitim (training) ve doğrulama(validation) setleri olmak üzere iki ana kategoriye ayrılır. Eğitim seti, ağın ağırlıklarını uygun bir şekilde ayarlayarak doğru tahminler yapabilmesi için kullanılır. Bu süreç sırasında ağ, verilen veri seti üzerindeki örüntüleri ve ilişkileri öğrenir. Diğer yandan, test seti, eğitim sürecinin bir parçası olmayan verilerle ağın ağırlıklarının doğruluğunu ve genelleştirme yeteneğini değerlendirmek için kullanılır. Bu ayrım, ağın hem öğrenilen veriler üzerinde etkili olmasını hem de daha önce karşılaşmadığı veriler üzerinde doğru tahminler yapabilmesini sağlar (Priddy vd., 2005) .

Çok katmanlı sinir ağı modelleri, ileri besleme ve geri yayılım yöntemi ile eğitilmektedir. Geri yayılım yönteminin ilk adımında, değişkenler eğitim ağına sunulur. Her bir değişkenin her bir nöronu için bir ağırlık değeri atanarak, değerler ağırlıklar ile çarpılıp toplandıktan sonra, bias değerinin eklenmesiyle gizli katmandaki nöronlarda bir aktivasyon fonksiyonu ile sonraki katmandaki tüm nöronlara gönderilir. Bu değerler, çıkış katmanındaki nöronlar için giriş değerlerini oluşturmaktadır. Çıkış katmanında benzer işlemler gerçekleştirildikten sonra bir çıktı değeri elde edilerek, çıktı ile gerçek değer karşılaştırılır ve hata değeri elde edilir.

$$\hat{y}_l = f_2 \left(\sum_{j=1}^R w_{kj}^{(2)} \left[f_1 \left(\sum_{j=1}^R w_{kj}^{(1)} x_j + b_k^{(1)} \right) \right] + b_k^{(2)} \right) \quad (3.3)$$

Denklem 3.3'te f_1, f_2 : aktivasyon fonksiyonu olmakta, w_{kj} : ağırlıkları, x_j girdileri b_k ise Bias değerini ifade etmektedir.

$$E_D = \frac{1}{2} \sum_{i=1}^p (y_i - \hat{y}_i)^2 \quad (3.4)$$

Denklem 3.4'te y_i gerçek değerleri, $\hat{y}_i$ ise tahmin değerlerini ifade etmektedir.

Eğitimin ikinci aşamasında, çıkış katmanında hesaplanan hata değerleri, ağırlık katmanları boyunca geriye doğru yayılır. Bu süreçte, hataların her bir katmanda nöronların ağırlıklarına olan etkisi hesaplanır. Bu hesaplama, ağırlıkların kayıp fonksiyonunun eğimini belirlemek için kullanılır. Böylece, ağırlık performansını iyileştirmek ve hata değerlerini azaltmak için ağırlıklar, belirli bir optimizasyon tekniği kullanılarak güncellenir (Li, 2017). Bu süreçte, türevde zincir kuralı kullanılarak ağırlıkların kısmi türevleri hesaplanır (denklem 3.5 ve 3.6). Bu adım, ağırlık öğrenme sürecinin temelini oluşturur ve modelin karmaşık veri setlerinden önemi bilgileri çıkarma yeteneğini sürekli olarak geliştirir. Ağırlıkların güncelleştirme işlemi, mimarinin öğrenme süreci olarak ifade edilmekte ve denklem 6 ile gösterilmektedir.


$$\frac{\partial E_b(t)}{\partial w_{kj}^2(t)} = \frac{\partial E_b(t)}{\partial n_k^2(t)} \frac{\partial n_k^2(t)}{\partial w_{kj}^2(t)} \quad (3.5)$$

$$\frac{\partial E_D(t)}{\partial b_k^2(t)} = \frac{\partial E_D(t)}{\partial n_k^2(t)} \frac{\partial n_k^2(t)}{\partial b_k^2(t)} \quad (3.6)$$

$$w^{l+1} = w^l - \alpha \frac{\partial E_D}{\partial w^l} \quad (3.7)$$

Evrişimli Otokodlayıcı Sinir Ağı Mimarisi

Derin öğrenme, veri temsil etme ve öğrenme kapasitesiyle bilgisayar bilimi ve yapay zekâ alanlarında hızla büyüyen bir alandır. Bu alandaki önemli yaklaşımlardan biri, evrişimli otokodlayıcı sinir ağlarıdır (CAE) (Şekil 3.). Evrişimli otokodlayıcılar, geleneksel otokodlayıcıların (Şekil 3.) bir varyasyonudur. Temel olarak, giriş verisini bir dizi katman aracılığıyla daha düşük boyutlu bir temsile dönüştüren ve ardından bu temsili tekrar orijinal veriye benzer bir çıktıya geri dönüştüren bir sinir ağıdır. Evrişimli otokodlayıcılar, bu süreçte evrişimli katmanlar (convolutional layers) kullanır. Evrişimli katmanlar, genellikle görüntü işleme görevlerinde kullanılır. Bu katmanlar, görüntülerdeki yerel özellikleri (örneğin, kenarlar, doku gibi) etkili bir şekilde yakalamak için tasarlanmıştır. Evrişim işlemi, her bir pikselin komşularıyla birlikte ele alınarak, belirli bir filtre veya çekirdek (kernel) ile çarpılıp toplanması şeklinde çalışır. Bu işlem, verinin yüksek seviyeli özelliklerini korurken boyutunu azaltmaya yardımcı olur.




Şekil 3.3 Otokodlayıcı Mimarisi

Evrişimli otokodlayıcıların temel bileşenleri şunlardır:

Kodlayıcı (Encoder): Giriş verisini alır ve daha düşük boyutlu bir temsil (kod) oluşturmak için evrişimli katmanlarından geçirir. Bu süreç, verinin boyutunu azaltırken önemli özelliklerini korumayı amaçlar.

Gizli soyut uzay (gizli katman): Kodlayıcı tarafından üretilen, giriş verisinin sıkıştırılmış temsidir. Bu, genellikle verinin daha düşük boyutlu bir temsidir ve otokodlayıcının öğrendiği temel özellikleri içerir.

Çözücü (Decoder): Gizli soyut uzay katmanını alır ve orijinal veriye mümkün olduğunca yakın bir çıktı üretmeye çalışır. Bu, genellikle ters evrişim (deconvolution) veya yukarı örnekleme (upsampling) katmanları kullanılarak gerçekleştirilir.



Şekil 3.4. Örnek bir evrişimli otokodlayıcı sinir ağı mimarisi gösterimi

Evrişimli otokodlayıcılar özellikle görüntü ve sinyal işleme gibi yüksek boyutlu veri türleri üzerinde çalışırken öne çıkmaktadır. Bu çalışmada da uydu görüntülerinden elde edilen verilerle, aynı koordinatlara karşılık gelen öznetelik haritası kullanılarak bir evrişimli otokodlayıcı modeli eğitilmiştir. Çalışmamızda benimsenen evrişimli otokodlayıcı modeli, geleneksel otokodlayıcı yapılarından bir önemli yönüyle ayrılmaktadır: Girdi verisi ile çıktı verisi arasında doğrudan bir eşleşme olmamakla birlikte, bu iki veri birbirleriyle ilişkilidir. Bu durum, modelimizin çapraz otokodlayıcı (cross autoencoder) olarak adlandırılmasına neden olmaktadır. Çapraz otokodlayıcılarda, kodlayıcı bölümü tarafından işlenen girdi verisi, çözücü bölümü tarafından farklı, ancak ilişkili bir çıktıya dönüştürülür. Bu yaklaşım, modelin veri setindeki karmaşık ilişkileri anlamasına ve bu bilgiyi yeni, ama ilişkili çıktılar üretmek için kullanmasına olanak tanır.

Otokodlayıcı sinir ağı modelinin eğitim sürecinde, uydu görüntülerinden elde edilen verilerle, aynı koordinatlara karşılık gelen öznetelik haritasının karşılıklı özellikleri arasında bir ilişki kurulmuştur (Şekil 3.). Bu ilişkilendirme, modelin genellemesini artırmak ve daha sonra yapılacak olan test sürecinde daha başarılı sonuçlar almasını sağlamak için kritik bir öneme sahiptir.

Evrişimli katmanlar, öğrenilen filtreler aracılığıyla giriş verisinin farklı bölgelerindeki özellikleri tespit eder, bu da yerel desenlerin ve yapıların daha etkili bir şekilde yakalanmasına olanak tanır. Matematiksel olarak, bu işlem denklem 3.7’de tanımlanır:

$$\text{Çıktı}[i, j] = \sum_m \sum_n \text{Giriş}[i - m, j - n] \cdot \text{Filtre}[m, n] + b \quad (3.7)$$

Çıktı[i, j]: Çıktı görüntüsünün i, j konumundaki piksel değeri.

Giriş[i, j]: Giriş görüntüsünün i, j konumundaki piksel değeri.

Filtre[m, n]: Evriřim iřlemi sırasında kullanılan filtre, boyutu genellikle 3x3 veya 5x5 olabilir.

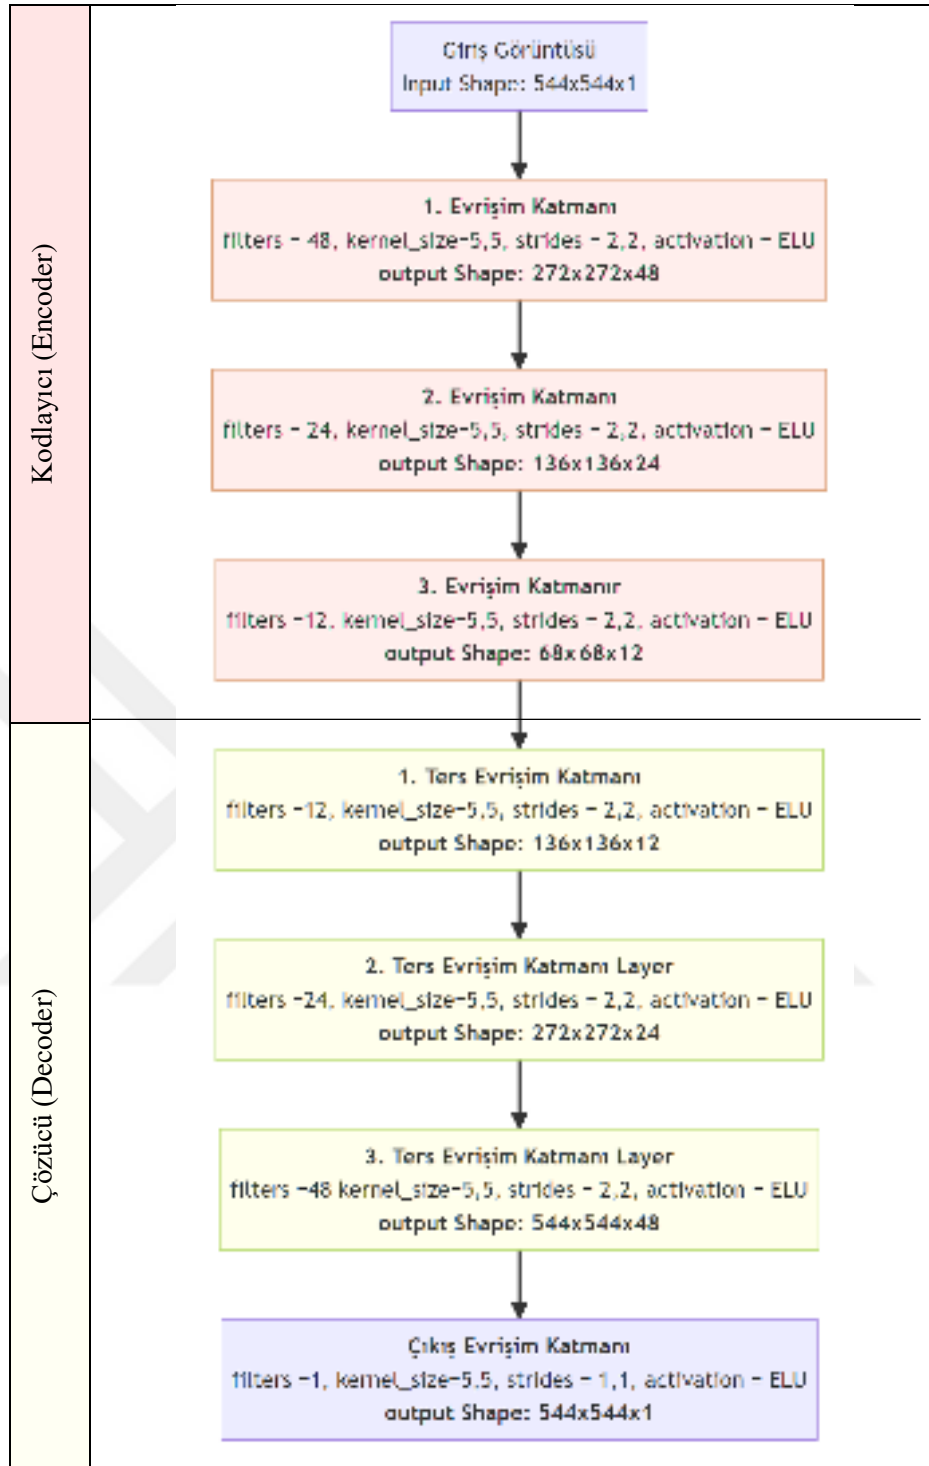
b: Yanlılık terimi(bias), her filtre için öğrenilen bir deęerdir.



Şekil 3.5. İha'nın aldığı NADİR görüntü, sinir ağı uygulamadan öncesi ve sonrası

Nihai Modelin Mimarisi

Bu çalışmada kullanılan evriřimli otokodlayıcı sinir ağıının mimarisi Şekil 3. 'te belirtilmiştir. Evriřimli otokodlayıcı mimari hem kodlayıcı (encoder) hem de kod çözme bölümlerinden oluşur. Aşağıda, her bir katmanın işlevi ve bu mimarinin nasıl oluşturulduęu detaylı olarak açıklanmaktadır.



Şekil 3.6 Nihai modelin mimarisinin gösterimi

Evrişimli Otokodlayıcı (Convolutional Autoencoder) sinir ağı mimarilerinde kullanılan eLU (exponential Linear Unit) aktivasyon fonksiyonu, derin öğrenme alanında önemli bir yenilik olarak kabul edilmektedir. Bu fonksiyonun tercih edilmesinin altında yatan temel neden, ReLU (Rectified Linear Unit) fonksiyonunun karşı karşıya kaldığı aktivasyon kaybı sorununa getirdiği çözümdür.

ReLU fonksiyonunun negatif girdiler için sıfır değerini döndürme özelliği, derin sinir ağlarının eğitim sürecinde önemli bir kısıtlama olarak ortaya çıkar (Parhi & Nowak, 2020). Bu

durum, negatif girdilere sahip nöronların aktivasyonlarının sürekli olarak engellenmesine yol açar, bu da nöronların etkin bir şekilde 'ölmesine' ve ağıın genel öğrenme kapasitesinin sınırlandırılmasına neden olur. Bu fenomen, derin öğrenme literatüründe 'ölü nöronlar' olarak adlandırılır ve özellikle karmaşık ve katmanlı ağ yapılarında ciddi bir sorun teşkil eder.

Buna karşılık, eLU aktivasyon fonksiyonu, negatif girdilerde sıfırdan farklı değerler üreterek bu sorunu aşar. Negatif girdiler için sürekli bir negatif eğim sağlaması, eLU'nun modelin negatif girdilere karşı duyarlılığını artırmasına ve öğrenme sürecinin daha stabil ve etkin bir şekilde ilerlemesine olanak tanır. Ayrıca, eLU'nun sürekli türevlenebilir olması, gradyan tabanlı optimizasyon algoritmalarının daha etkili bir şekilde çalışmasını sağlar. Bu özellik, özellikle derin ağ yapılarının eğitimi sırasında büyük önem taşır.

Bu avantajlar, eLU'nun derin sinir ağlarının daha geniş ve karmaşık veri setleri üzerinde daha etkin öğrenme ve daha yüksek performans göstermesini sağlamaktadır. Görüntü işleme, doğal dil işleme gibi alanlarda eLU aktivasyon fonksiyonunun kullanımı, modelin genelleme yeteneğini artırarak yüksek performans elde etmesine katkıda bulunmaktadır. Sonuç olarak, eLU aktivasyon fonksiyonu, modern derin öğrenme mimarilerinde yaygın olarak tercih edilen bir aktivasyon fonksiyonu haline gelmiş ve bu alanda yapılan araştırmalara önemli katkılar sağlamıştır. eLU aktivasyon fonksiyonu, denklem 8'deki matematiksel ifade ile tanımlanır ve Şekil 3.'te Elu aktivasyon fonksiyonunun görselleştirilmesi yer alır.

$$f(x) = x \text{ for } x > 0, \quad \alpha(e^x - 1) \text{ for } x \leq 0 \quad (3.8)$$



Şekil 3.7. ELU aktivasyon fonksiyonu gösterimi

Giriş Katmanı

Geliştirilen Modelin giriş katmanı, (544, 544, 1) boyutlarındaki veri seti ile uyumlu olacak biçimde tasarlanmıştır. Bu özel boyutlandırma seçimi ve gerekçeleri, çalışmanın 3.1.2 *Testlerde Kullanılacak Haritanın Temini* bölümünde detaylıca açıklanmıştır. Kısaca belirtmek gerekirse, bu boyutlandırma, verinin karakteristik özelliklerini korurken hesaplama verimliliği sağlamak, bellek kullanımını optimize etmek ve özellikle sinir ağı çıkışında kenar bozulmalarının getirdiği kusurların önüne geçmek için seçilmiştir. Giriş katmanı, modelimizin öğrenme sürecine başlamadan önce veriyi uygun hale getirme işlevi görür ve daha sonraki katmanlarda yapılacak derin özellik çıkarma işlemleri için veriyi hazırlar.

Kodlayıcı Bölümü (Encoder)

Kodlayıcı bölümü, girilen yüksek çözünürlüklü uydu görüntüsünün karmaşık yapısından anlamlı özelliklerin çıkarılmasını ve bu özelliklerin daha kompakt bir temsiline dönüştürülmesini hedefler. Bu süreçte, kodlayıcı katmanları, giriş görüntüsünün içerdiği zengin bilgiyi, sonraki çözücü bölümünün anlamlı etiket haritalarına dönüştürebileceği bir formata sıkıştırır.

Bu bölüm, giriş görüntüsünden öğrenilen özellikleri artan derinliklerde yoğunlaştırmak için tasarlanmıştır ve her bir katman, bu işlemde belirgin bir rol oynar:

İlk Evrişimli Katman (Conv2D)

48 filtre kullanarak, görüntünün temel doku ve kenar gibi özelliklerini yakalar. eLU aktivasyon fonksiyonu, bu temel özelliklerin lineer olmayan bir biçimde aktarılmasını sağlar, bu sayede model negatif girdileri de dikkate alarak daha zengin bir özellik seti öğrenebilir. Bu katmanın çıktı boyutu, girdi boyutunun yarısı kadar olacak şekilde 272x272x48'dir.

İkinci Evrişimli Katman (Conv2D)

24 filtre ile, ilk katmanda elde edilen özellikler üzerine inşa eder ve modelin daha karmaşık yapıları tanıma yetisini geliştirir. Bu katman, sıkıştırma sürecinde bilginin korunmasını sağlayarak, kodlayıcı'nın detay kaybına uğramadan veriyi işlemesine olanak tanır. Bu katmanın çıktı boyutu 136x136x24'tür.

Üçüncü Evrişimli Katman (Conv2D)

Bu katmanda kullanılan 12 filtre ile, kodlayıcı bölümünün son aşaması olarak, verinin en yüksek düzeyde sıkıştırılmasını gerçekleştirir. Bu noktada, öğrenilen özellikler maksimum derecede soyutlandırılmış olup, bu da çözücü tarafından detaylı bir semantik yeniden yapılandırmaya uygun bir temel oluşturur. Bu katmanın çıktı boyutu 68x68x12'dir.

Her bir katmandaki filtre sayısının azalması, modelin farklı ölçeklerde özellik çıkarma kabiliyetini ve özellik haritalarının derinliklerini yönetir, böylece kodlayıcı, girilen görüntünün

içerdiği bilgiyi etkili bir şekilde sıkıştırırken önemli semantik bilgileri koruyabilir. Bu strateji, çözücü'nün daha sonra, bu yoğunlaştırılmış temsili, uydu görüntülerine karşılık gelen keskin ve net etiket haritalarına dönüştürmesi için gereken detay ve karmaşıklığı sağlar. Kodlayıcı tarafından gerçekleştirilen bu özenli sıkıştırma işlemi, modelin etkin bir şekilde öğrenmesi ve gerçek dünya verilerine genelleme yapabilmesi için kritik öneme sahiptir.

Çözücü Bölüm (Decoder)

Çözücü bölümü, kodlayıcı tarafından işlenmiş ve sıkıştırılmış verinin semantik anlamda zenginleştirilmiş bir biçimde yeniden yapılandırılmasını hedefler. Bu yapılandırma işlemi, kodlayıcı tarafından elde edilen yoğunlaştırılmış özellik haritalarının, orijinal uydu görüntüsüne karşılık gelen etiket haritasına benzer bir çıktı üretmesini sağlamak için tasarlanmıştır. Böylece, model çıktısı, arazi kullanımı, bina yapıları ve yol ağları gibi özelliklerin belirginleştirildiği bir harita olarak ifade edilir.

Birinci Ters Evrişimli Katman (Conv2DTranspose)

12 filtre kullanarak, modelin semantik anlamda önemli özellikleri yeniden yapılandırmasına olanak tanır. Bu katman, sıkıştırılmış verinin ilk genişletilme aşamasını gerçekleştirir ve basit yapıları daha belirgin bir formata dönüştürmeye başlar. 68x68x12 boyutlu görüntüyü 136x136x12 boyuta ters evrişim uygulayarak getirir.

İkinci Ters Evrişimli Katman (Conv2DTranspose)

24 filtreye sahip bu katman, veriyi daha da detaylandırır ve özellik haritalarını daha net bir semantik yapıya kavuşturur. Bu aşamada, modelin detaylı özellikleri daha keskin bir şekilde yeniden oluşturmasını sağlar. 136x136x12 boyutlu görüntüyü 272x272x24 boyuta ters evrişim uygulayarak getirir.

Üçüncü Ters Evrişimli Katman (Conv2DTranspose)

48 filtre ile donatılmış bu son katman, verinin en ince detaylarını bile koruyarak yeniden yapılandırılmasını sağlar. Bu katmanın görevi, verinin son haliyle etiket haritasının hassasiyetini ve kalitesini en üst düzeye çıkarmaktır. 272x272x24 boyutlu görüntüyü 544x544x48 boyutuna ters evrişim uygulayarak getirir.

Çözücü, bu şekilde katman katman bir yapılandırma süreci işletirken, her adımda sıkıştırılmış verinin daha önce kodlayıcı tarafından tespit edilen özellikleri genişletir ve bu özellikleri, modelin eğitim verilerinde öğrendiği etiketlenmiş yapılara uygun bir biçimde yeniden düzenler. Bu kademeli genişletme ve düzenleme işlemi, modelin çıktısının gerçek dünya verilerini yansıtan doğru ve anlamlı bir harita oluşturmasını sağlar ve bu özellik, modelin pratik uygulamalarda etkin kullanımının temelini oluşturur.

Çıkış Katmanı (Conv2D)

Bu araştırmada tasarlanan evrişimli sinir ağı modelinin çıkış katmanı, uydu görüntülerinden elde edilen karmaşık verilerin işlenmesi ve basitleştirilmesi sürecinin son aşamasını temsil eder. Bu katman, modelin kodlayıcı ve çözücü bölümlerinde işlenmiş ve sıkıştırılmış verileri, şablon eşleme algoritmasının etkinliğini artırmak için optimize edilmiş bir çıktıya dönüştürür. Bu çıktı, uydu görüntüsündeki binalar, yollar ve diğer kritik kentsel özellikler ile çevresel arka plan arasında belirgin bir ayrım sağlayacak şekilde siyah ve beyaz tonlar arasında gradyanlar oluşturur. Böylece, algoritmanın, değişen ışık koşulları, mevsimsel etkiler ve gölgeleme gibi faktörlerden minimum etkilenmesi hedeflenmiştir.

Çıkış katmanı, tek bir kanal üzerindeki 5x5'lük filtrelerle yapılandırılmıştır ve aktivasyon fonksiyonu olarak 'sigmoid' tercih edilmiştir. 'Sigmoid' fonksiyonunun kullanımı, modelin çıktısının, piksel bazında siyah-beyaz tonları ile bu tonlar arasındaki geçişleri net bir şekilde ayırt edebilmesini sağlar. Bu tonlama yöntemi, modelin çıktısında, binalar ve yollar gibi özelliklerin yanı sıra, bu özelliklerin çevresel matris içerisindeki konumlarını da açıkça gösterir. Bu yaklaşım, modelin çıktısının, gerçek dünya verilerini temsil ederken görsel ayrıntı ve ton farklılıklarını da dikkate almasını sağlar.

Model, toplamda 78169 eğitilebilir parametre içerir. Bu parametreler, modelin giriş verisini, şablon eşleme için uygun bir çıktıya dönüştürme sürecindeki her adımda maksimum hassasiyet ve doğrulukla işlemesi için detaylı bir şekilde optimize edilmiştir. Bu detaylı yapılandırma, modelin uygulamalı alanlarda karşılaşılabilecek farklı senaryolarda güvenilir ve tekrar edilebilir sonuçlar üretmesini sağlar. Bu özellik, modelin teorik altyapısının pratik uygulamalarla nasıl bütünleştiğini gösteren önemli bir örnek teşkil eder ve algoritmanın etkinliğinin artırılmasında kritik bir rol oynar.

Model Tasarımı ve Parametre Optimizasyonu

Modelin mimarisindeki kritik bileşenlerden biri olarak, evrişimli katmanlarda kullanılan filtre boyutları ve adım sayıları (strides) üzerine titiz bir optimizasyon süreci yürütülmüştür. Temel özellik çıkarımı için çeşitli filtre boyutları (2x2, 4x4, 5x5, 7x7 ve 9x9) ve farklı adım değerleri dikkatle değerlendirilmiş, karşılaştırmalı performans analizleri yapılmıştır. Bu analizler, eğitim süresi, hesaplama maliyeti, model karmaşıklığı ve nihai segmentasyon performansı gibi faktörleri kapsamlı bir şekilde ele almıştır.

Her bir filtre boyutu ve adım değeri, modelin eğitim veri setindeki ve doğrulama veri setindeki performansını, özellikle semantik segmentasyon doğruluğu ve sınıflandırma metrikleri açısından test edilmiştir. 5x5 boyutundaki filtreler ve (2,2) adım değerleri, diğer seçeneklere kıyasla daha yüksek doğruluk oranları ve genelleme kabiliyeti göstermiş, aynı zamanda hesaplama verimliliği açısından da en dengeli seçenek olarak ön plana çıkmıştır. Bu bulgular ışığında hem kodlayıcı hem de çözücü bölümlerinde 5x5 boyutunda filtrelerin ve (2,2) adım değerlerinin kullanılması kararı alınmıştır. Bu seçim, modelin yüksek çözünürlüklü uydu görüntülerinden


detaylı ve hassas özellikler çıkarabilmesine imkân tanırken, aynı zamanda ölçeklenebilirlik ve işlemsel etkinlik gereksinimlerini de karşılamaktadır.

Bu deneysel kararın altını çizmek gerekirse, model tasarım sürecindeki bu metodolojik yaklaşım, bilimsel titizliği ve yenilikçi mühendislik çözümlerini bir araya getirmekte, böylece modelin uygulamalı alanlarda sağlam ve güvenilir sonuçlar vermesinin temelini oluşturmaktadır. Bu yaklaşım, modelin geniş veri setleri üzerinde etkili genelleme yapabilmesini ve gerçek dünya uygulamalarında yüksek doğruluk oranlarına ulaşabilmesini sağlar.

Eğitim Aşaması

Bu araştırmada, modelin eğitim süreci için özel olarak derlenmiş bir veri seti kullanılmıştır. Bu veri seti, toplam 406.579 adet 544x544 piksel boyutunda tek kanallı gri-ölçek görüntüden oluşmaktadır. Bu görüntülerin rastgele olarak %10'u doğrulama seti olarak ayrılmış, geriye kalan %90'lık kısmı ise evrişimli sinir ağının eğitim sürecinde kullanılmıştır. Araştırmada, evrişimli sinir ağlarının performansını etkileyen kritik parametreler dikkate alınmıştır. Bu parametreler arasında çeşitli çekirdek (kernel) boyutları, farklı kanal (channel) sayıları ve çeşitli adım (stride) boyutları bulunmaktadır. Bu parametrelerin farklı kombinasyonları kullanılarak bir dizi model tasarlanmış ve bu modellerin performansları kapsamlı bir şekilde test edilmiştir. Bu süreç, modelin en etkili yapılandırmasını belirlemek ve sinir ağının genel performansını optimize etmek için kritik öneme sahiptir.

Modelin eğitimi, 250 epoch boyunca gerçekleştirilmiştir, burada her bir epoch veri setinin tamamının model tarafından bir kez işlenmesi anlamına gelir. Mini-batch yöntemi kullanılarak her bir batch'te 32 görüntü işlenmiştir. Her 10 epoch'da modelin güncel versiyonu kaydedilmiş ve performansı değerlendirilmiştir. Eğitim sürecinde kayıp fonksiyonunun değişimi Şekil 3.'te verilmiştir. Veri setimizin zengin çeşitliliği ve büyüklüğü nedeniyle, veri artırma (data augmentation) teknikleri kullanılmamıştır.



Şekil 3.8 Sinir ağı eğitim sürecinde eğitim ve doğrulama kaybı

Model optimizasyon süreci, çeşitli hiper parametreler üzerinde kapsamlı denemeler yapılarak gerçekleştirilmiştir. Optimal sonuçlar elde edilen model konfigürasyonunda, öncelikle kayıp fonksiyonu olarak denklem 9’da belirtilen Ortalama Karesel Hata (Mean Squared Error- MSE) kullanılmıştır. MSE, modelin tahminleri ile gerçek değerler arasındaki farkların karesinin ortalamasını alarak, modelin doğruluğunu ve performansını değerlendirir. Bu metrik, modelin hedef değerlere olan yakınlığını ve tahminlerinin hassasiyetini gösterir, dolayısıyla modelin genel doğruluğu hakkında önemli bilgiler sağlar.


$$MSE = \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (3.9)$$

Ayrıca, modelin optimizasyon algoritması olarak ADAM (Adaptive Moment Estimation) seçilmiştir. ADAM, stokastik gradyan inişi (SGD) metodunun adaptif öğrenme oranlarına sahip bir varyantıdır. Bu algoritma, her bir parametrenin öğrenme oranını dinamik olarak ayarlayarak, modelin eğitim sürecinde daha hızlı ve etkili bir şekilde konverjans (minimum kayıp değerine yakınsama) sağlamasına yardımcı olur. ADAM, özellikle derin öğrenme uygulamalarında yüksek verimlilik ve hız avantajları nedeniyle sıklıkla tercih edilir (Kingma & Ba, 2017).

Son olarak, modelin öğrenme oranı (learning rate) olarak 0.0001 değeri belirlenmiştir. Öğrenme oranı, modelin ağırlıklarını ne kadar hızlı güncelleyeceğini belirleyen kritik bir hiper parametredir. Çok düşük bir öğrenme oranı, modelin eğitim sürecinin yavaşlamasına ve lokal minimumlarda takılmasına neden olabilirken, çok yüksek bir öğrenme oranı ise modelin optimum çözümleri atlamasına ve istikrarsız sonuçlara yol açabilir. Seçilen 0.0001 değeri, bu dengeyi koruyarak modelin hem etkili hem de kararlı bir şekilde eğitilmesini sağlamaktadır.


3.2.2. Şablon Eşleme Algoritması ile Testler

Bu çalışmanın test aşamasında, evrişimli sinir ağı modeli, öncelikle İHA'nın uçuş gerçekleştireceği bölgenin haritasına uygulanarak, bu haritada belirli özellikleri ve yapıları tanımlamak için kullanılmıştır. Ardından, bu işlem, İHA tarafından anlık olarak çekilen görüntülere uygulanmış ve bu iki farklı veri kaynağı arasında karşılaştırmalı bir benzerlik analizi gerçekleştirilmiştir (Şekil 3.). Bu sürecin temel amacı, modelin haritada işaretlediği özelliklerle, İHA'nın gerçek zamanlı çektiği görüntülerdeki özellikler arasında yüksek düzeyde korelasyon bulmak ve böylece İHA'nın konumunu harita üzerinde doğru bir şekilde belirleyebilmektir.



Şekil 3.9 Arazi üzerinde İHA'nın konum belirleme modeli (Duo & Zhao, 2017)

senaryolarında, özellikle navigasyon ve konum tespiti gibi kritik görevlerde, yüksek performans ve doğruluk sergileyebilmesinin altını çizer. Şekil 3.'da İHA'nın aldığı nadir görüntülere otokodlayıcı sinir ağı uygulama öncesi ve sonrası görülmektedir.



Şekil 3.11. İha'dan alınan görüntülerin sinir ağı uygulanmadan önce ve sonrası

Son olarak, bu yöntemin kullanılması, İHA'nın gerçek zamanlı olarak konumunu tespit edebilmesi ve bu konumu doğru bir şekilde haritada gösterebilmesi için büyük bir öneme sahiptir. Özellikle dinamik ve değişken koşullarda, bu tür bir yaklaşımın İHA'nın başarılı bir şekilde navigasyon yapabilmesi için kritik bir rol oynadığı düşünülmektedir. Denklem 3.10'da NCC algoritmasının matematiksel formülü görülmektedir.

$$R(x, y) = \frac{\sum_{x', y'} (f(x + x', y + y') - \bar{f}(x, y)) (t(x', y') - \bar{t})}{\sqrt{\sum_{x', y'} (f(x + x', y + y') - \bar{f}(x, y))^2} \sqrt{\sum_{x', y'} (t(x', y') - \bar{t})^2}} \quad (3.10)$$

- $R(x, y)$ korelasyon katsayısını temsil eder.
- $f(x, y)$ görüntünün her bir pikselinin yoğunluğunu temsil eder.
- $t(x', y')$ şablonun veya küçük görüntünün her bir pikselinin yoğunluğunu temsil eder.
- $\bar{f}(x, y)$ Ve $\bar{t}$, sırasıyla, f ve t içindeki piksellerin ortalamasını temsil eder.
- x', y' toplamaların alındığı indislerdir ve şablonun boyutlarına bağlıdır.

Görüntü Dönüşümü ve Optimizasyonu

İHA'dan alınan anlık görüntüler renkli formda 3 kanala sahiptir. Ancak, renkli görüntü kullanımının, evrişimli otokodlayıcı sinir ağı ve şablon eşleme performansına anlamlı bir katkı sağlamadığı gözlemlenmiştir. Bu nedenle, işlem yükünü azaltmak ve algoritmanın hızını optimize etmek amacıyla, görüntüler tek kanallı gri-ölçek formata dönüştürülmüştür.

İHA'dan alınan renkli görüntülerin (RGB formatında) tek kanallı griölçek (grayscale) formata dönüştürülmesi matematiksel olarak şu şekilde ifade edilebilir (Bala & Eschbach, 2004):

$$Y = 0.299R + 0.587G + 0.114B \quad (3.11)$$

Burada R , G ve B , sırasıyla kırmızı, yeşil ve mavi renk kanallarını temsil ederken, Y ise elde edilen siyahbeyaz (grayscale) görüntüdür. Bu dönüşüm, evrişimli otokodlayıcı sinir ağının işlem yükünü azaltırken, görüntüden elde edilen bilgiyi korumaya yardımcı olur.

Daha sonra, alınan nadir görüntüler, İHA'nın manyetik yön bulma sensöründen alınan veriler kullanılarak coğrafi kuzey yönüne döndürülür. Bu işlem, dönüşüm matrisi $R(\theta)$ kullanılarak gerçekleştirilir:

$$R(\theta) = \begin{pmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{pmatrix} \quad (3.12)$$

Bu matris, bir noktanın orijinal koordinatları (x, y) üzerinde döndürme işlemi yaparak yeni koordinatları (x', y') elde etmek için kullanılır. Matematiksel olarak bu işlem şu şekilde ifade edilir:

$$\begin{pmatrix} x' \\ y' \end{pmatrix} = R(\theta) \begin{pmatrix} x \\ y \end{pmatrix} \quad (3.13)$$

Bu ifade detaylandırıldığında, yeni koordinatlar aşağıdaki gibi hesaplanır:


$$x' = x \cos(\theta) - y \sin(\theta), \quad y' = x \sin(\theta) + y \cos(\theta) \quad (3.14)$$

Bu dönüşüm, özellikle şablon eşleme algoritmalarının doğruluğu ve yön duyarlılığı açısından kritik öneme sahiptir. Ancak, İHA tarafından elde edilen görüntüler, dönüşüm matrisi işlemi sonucunda küsuratlı sayılar üretebilir. Bu durum, görüntüde interpolasyon gerekliliğini doğurur. İnterpolasyon, dönüşüm sırasında oluşabilecek piksel boşluklarını doldurarak görüntü kalitesini korumak için kullanılan bir tekniktir. Bilinear veya bicubic gibi interpolasyon teknikleri, bu süreçte sıkça başvurulan yöntemler arasındadır. Çalışmada bilinear interpolasyon (Smith, 1981) tekniği kullanılmıştır.

Sonuç olarak, bu dönüşüm ve optimizasyon süreçleri, İHA tarafından elde edilen görüntülerin işlenmesinde verimliliği ve doğruluğu artırmak için kritik öneme sahiptir. Bu teknikler, veri işleme yükünü azaltırken, şablon eşleme ve görüntü tanıma algoritmalarının performansını maksimize etmekte ve böylece İHA tabanlı görsel navigasyon sistemlerinin etkinliğini artırmaktadır.

Uzamsal Çözünürlüğün Hesaplanması

Şablon eşleme algoritmaları, uzamsal çözünürlüğe karşı da oldukça duyarlıdır. Bu nedenle, kameranın odak uzaklığı, sensör boyutu ve uçuş yüksekliği gibi parametreler dikkate alınarak, alınan görüntülerin uzamsal çözünürlüğü hesaplanır. Uzamsal çözünürlük, İHA tarafından çekilen görüntülerin yeryüzündeki birim alan başına düşen piksel sayısını ifade eder ve bir görüntünün detay seviyesini belirleyen kritik bir metriktir. Bu değer, İHA'nın uçuş yüksekliği (H) ile doğrudan orantılı olarak değişkenlik gösterir ve sensör genişliği (Sw) ile odak uzaklığı (f) gibi kameranın optik özellikleri tarafından modüle edilir (Şekil 3.19.). Bu işlem için İHA'nın aldığı görüntünün uzamsal çözünürlüğü aşağıdaki formüle göre hesaplanır (Yang vd., 2016).



Şekil 3.19. Uzamsal çözünürlük hesaplamak için kullanılan parametrelerin gösterimi(*What Is Ground Sampling Distance (GSD) In Photogrammetry?*, 2022)

$$\text{Mekansal Çözünürlük} = \frac{\text{Sensör Genişliği}(SW_{\text{milimetre}}) \times \text{uçuş yüksekliği}(H_{\text{metre}})}{\text{Odak uzaklığı}(f_{\text{milimetre}}) \times \text{Görüntü Genişliği}(IMw_{\text{piksel}})} \quad (3.15)$$

Bu formülde:

- **Sensör Genişliği (SW)**, kamera sensörünün genelde yatay eksenindeki fiziksel genişliğini temsil eder. Bu ölçüm, genellikle milimetre cinsinden verilir ve sensörün görüş açısını ve dolayısıyla görüntü boyutunu belirlemede esas alınır.
- **Uçuş yüksekliği(H)**, İHA'nın arazi üzerinden dikey olarak ölçülen yüksekliğidir. Metre cinsinden ifade edilir ve hem görüntüleme alanını hem de görüntü çözünürlüğünü etkiler. Uçuş yüksekliği arttıkça, yerdeki görüntü genişliği de büyür, ancak bu durum aynı zamanda piksel başına düşen gerçek alanı da artırarak görüntü detaylarını azaltabilir.
- **Odak uzaklığı(f)** kameranın optik merkezinden sensörün odak noktasına kadar olan mesafeyi ifade eder. Milimetre cinsinden ölçülür ve kamera lensinin büyütme kapasitesini gösterir. Odak uzaklığı, görüntülenen sahanın ne kadarının sensör tarafından yakalanabileceğini ve dolayısıyla görüş alanının genişliğini belirler.
- **Görüntü genişliği (IMw)**, İHA tarafından alınan görüntünün piksel cinsinden genişliğidir. Bu değer, görüntünün dijital çözünürlüğünü ve dolayısıyla detay seviyesini

gösterir. Yüksek bir IMw değeri, genellikle daha fazla detayın ve daha net bir görüntünün elde edilmesini sağlar.

Hesaplanan uzamsal çözünürlük, verilen bir yükseklikte İHA'nın kamerası tarafından çekilen görüntünün her bir pikselinin gerçekte ne kadar yeryüzü alanını temsil ettiğini gösterir. Daha düşük uzamsal çözünürlük değerleri, daha yüksek detay seviyesine işaret ederken, daha yüksek uzamsal çözünürlük değerleri daha geniş bir alanın daha az detayla kaplanmasını ifade eder.

Bu hesaplama, İHA'nın yüksekliğini ve kameranın optik parametrelerini göz önünde bulundurarak, çekilen görüntülerin yeryüzündeki gerçek ölçeklenmesini anlamak için esastır. Görüntünün uzamsal çözünürlüğünü doğru bir şekilde hesaplamak, haritalandırma, arazi kullanımı analizi, afet izleme gibi alanlarda uygulamaların doğruluğunu ve etkinliğini artırır. Bu nedenle, İHA tabanlı uzaktan algılama projelerinde, araştırmacılar ve mühendisler için bu hesaplamaların doğru yapılması ve sonuçların doğru yorumlanması büyük önem taşımaktadır.

İrtifa Ölçümünün Geliştirilmesi ve Araziden Yükseklik Tahmini


Bu çalışmada, İnsansız Hava Araçları (İHA)'nın irtifa ölçüm doğruluğu, modelin gerçek dünya uygulamalarındaki performansı için hayati bir faktör olarak ele alınmaktadır. Lazer mesafe ölçerler (Cai vd., 2015) gibi gelişmiş sensörler, yüksek hassasiyet sunmalarına rağmen, bunların yüksek maliyetleri ve İHA sistemlerine ekstra ağırlık yüklemesi gibi dezavantajlarının farkında olarak, alternatif yöntemler araştırılmıştır. Bu çerçevede, daha ekonomik ve hafif bir çözüm olarak barometrik sensörlerin kullanımı önerilmiştir. Bu sensörler, yer yüzeyinden itibaren irtifa ölçümlerinde kullanılabilir ve verimli bir alternatif sunabilir.

Barometrik sensörler, deniz seviyesinden irtifa ölçümü yaparken, araziden olan gerçek yüksekliği doğrudan göstermemektedir. Bu durumun üstesinden gelmek için, İHA'nın bulunduğu koordinatlarda Sayısal Yükseklik Modeli (SYM) haritasındaki yükseklik değerleri dikkate alınmıştır. İHA'nın barometrik sensörü simüle eden GPS sensöründen elde ettiği irtifa değerinden, bu koordinatlardaki SYM haritasındaki rakım çıkarılarak, İHA'nın araziye olan gerçek yüksekliği hesaplanmıştır. Bu metodoloji, İHA'nın araziye olan efektif yüksekliğini hesaplamada kritik bir rol oynamaktadır ve navigasyonun doğruluğunu artırmaktadır (Şekil 3.).

Burada dikkate alınması gereken önemli bir nokta da SYM haritasının uzamsal çözünürlüğüdür. Uzamsal çözünürlük, haritanın her bir pikselinin temsil ettiği gerçek dünya alanının büyüklüğünü ifade eder. Yüksek uzamsal çözünürlüğe sahip bir SYM haritası, daha detaylı arazi bilgisi sunar ve İHA'nın navigasyon sistemlerinin hassasiyetini artırır. Özellikle karmaşık veya değişken arazi yapılarına sahip bölgelerde, yüksek çözünürlüklü SYM haritalarının kullanılması, İHA'nın gerçek zamanlı ve doğru yükseklik ölçümleri yapabilmesi için kritik önem taşır. Bu, arazinin küçük özelliklerini ve değişikliklerini daha iyi yansıtır, dolayısıyla İHA'nın araziye olan gerçek yüksekliğinin daha doğru bir şekilde hesaplanmasını sağlar. Ayrıca, detaylı SYM haritaları, İHA'nın

karşılaşılabileceği potansiyel engelleri ve navigasyon zorluklarını daha iyi tahmin etmesine olanak tanır.

Gerçekleştirilen bu analiz, İHA tabanlı navigasyon sistemlerinin doğruluğunu önemli ölçüde artırırken, aynı zamanda daha geniş çevresel koşullarda İHA'nın etkin kullanımına olanak tanımaktadır. Barometrik sensörleri simüle ederek elde edilen verilerin SYM haritası ile birleştirilmesi, İHA'nın yer yüzeyine olan efektif yüksekliğinin doğru bir şekilde tahmin edilmesine katkıda bulunmuştur. Bu yaklaşım, İHA tabanlı haritalama ve navigasyon tekniklerinin geliştirilmesinde önemli bir adım teşkil etmekte ve bu alandaki araştırmalar için yeni kapılar açmaktadır.



Şekil 3.12. İha'nın İrtifa Parametrelerinin Gösterimi

Harita ve Görüntü Uzamsal Çözünürlüğünün Uyumlanması

İHA tarafından elde edilen görüntülerin ve kullanılacak haritanın uzamsal çözünürlüklerinin uyumlaştırılması için, ilk olarak, İHA görüntüsünün Uzamsal Çözünürlüğü anlatılan yöntemler kullanılarak hesaplanır. Bu hesaplama, görüntülerin şablon eşleme süreçlerinde kullanılacak harita ile uzamsal olarak uyumlu olmasını sağlamak amacıyla gerçekleştirilir.

Görüntü ve haritanın uzamsal çözünürlüklerinin eşleştirilmesi, İHA'nın aldığı görüntünün uzamsal çözünürlüğünün haritanın uzamsal çözünürlüğü ile oranlanması ile başlar. Bu oran, görüntünün harita üzerinde doğru bir şekilde konumlandırılması ve daha isabetli şablon eşleme başarımı sağlanması için kritik öneme sahiptir. Görüntünün ölçeklendirilmesi, bilinear interpolasyon algoritması kullanılarak yapılır. Bu yöntem, görüntünün piksellerini belirlenen orana göre yeniden düzenleyerek, uyumun sağlanmasında etkili bir rol oynar.

Bilinear interpolasyon yöntemi, görüntü ölçeklendirme işlemlerinde kullanılan, piksel tabanlı bir tekniktir. Bu yöntem, yeni piksellerin değerlerini hesaplarken, ölçeklenen görüntünün

mevcut pikselleri arasında bulunan dört en yakın komşu pikselin değerlerini kullanır. Bu dört pikselin değerleri, hedef pikselin konumuna göre ağırlıklandırılarak birleştirilir, böylece daha yumuşak ve doğal bir görüntü geçişi sağlanır.

Performans açısından, bu yöntem hız ve görüntü kalitesi arasında etkili bir denge sunar. Gelişmiş görsel kalite sağlamasına karşın, hesaplama süresi açısından da verimlidir. Bu dengeli yaklaşım, özellikle orta ve yüksek çözünürlüklü görüntülerin işlenmesinde önem taşır. Bilinear interpolasyon, özellikle düz hatlar, kenarlar ve yüzey geçişleri gibi öğelerde görsel açıdan tatmin edici sonuçlar üretir.

Özellikle şablon eşleme algoritmasının hassasiyetinin artırılmasında ve İHA'nın sağladığı görüntü verilerinin harita ile doğru bir şekilde eşleştirilmesinde bu metodolojik yaklaşımın önemi büyüktür. Görüntü ve haritanın uzamsal çözünürlüklerinin eşleştirilmesi, İHA tabanlı sistemlerin gerçek dünya koşullarında daha güvenilir ve doğru sonuçlar üretmesine olanak tanır.

Şablon Eşleme ve Konum Tespiti (Performans testleri, metrikler)

Uzamsal çözünürlüklerin uyumlanması ve görüntü işleme yöntemlerinin ardından, bu bölümde İHA'nın elde ettiği ve işlenen görüntülerin şablon eşleme ve konum tespiti süreçlerine odaklanılacaktır.

Otokodlayıcı sinir ağının 544x544 piksel boyutlu görüntüler üzerinde eğitilmiş olması nedeniyle, coğrafi kuzeye yönlendirilmiş ve uzamsal çözünürlüğü şablon eşleme yapılacak harita görüntüsü ile uyumlanmış İHA'nın aldığı nadir görüntüden, x ve y koordinatlarında 100 piksel fark olacak şekilde üç ayrı 544x544'lük görüntü alınır(Şekil 3.).


Evrişimli sinir ağlarının görüntünün kenar bölgelerinde genellikle bozulmalara sebep olması nedeniyle(Alsallakh vd., 2020), her bir 544x544 piksel boyutundaki görüntüden dört kenarından 16 piksel kesilerek, 512x512 piksel boyutuna indirgenir.

Bu 512x512'lik 3 görüntü, Normalize Edilmiş Çapraz Korelasyon Katsayısı şablon eşleme algoritması(Ching, 1995) ile daha önceden otokodlayıcı sinir ağıyla dönüştürdüğümüz haritada, konumları bulunmaya çalışılır. Eğer üç farklı görüntü kesişiyorsa, bu kesişen noktaların merkezi İHA'nın anlık konumu olarak kabul edilir. Şayet sadece iki görüntü kesişiyorsa, bu iki görüntünün kesişim noktasının merkezi anlık konum olarak kabul edilir. Kesişim olmuyorsa görüntü bulunamadı olarak kabul edilir. Bir uçuş rotası boyunca gerçek konum ile tahmin edilen konum arasındaki fark 30 metreden az ise konum doğru bulundu olarak kabul edilir.

Elde edilen konum tahminlerinin doğruluğunun teyit edilmesi amacıyla, GPS sensöründen elde edilen gerçek zamanlı koordinat verileri referans alınmıştır. Bu sayede, İHA'nın tahmini konumu ile gerçek konumu arasındaki uyumluluk ve doğruluk derecesi değerlendirilmiştir.

Seilen 30 metre hata marjı, literatürde sıklıkla rastlanan 10-20 metre hata marjlarına kıyasla daha geniş bir toleransı temsil etmektedir. Daha dar hata marjları santimetre ölçeğinde kontrol edilebilecek GPS modülleri olmadan ve coğrafi referans sistemindeki dönüşümlerin hata payları göz önüne alınınca gerçek dünya uygulamalarında sıklıkla başarısız olabilirler. Önceki çalışmalar, genellikle ideal koşullar altında gerçekleştirilmiş olup, atmosferik değişkenler, sinyal kaymaları veya engeller gibi olası dış etkenleri dikkate almamıştır (Yamamoto vd., 2018). Bu nedenle, çalışma 30 metre hata marjını, gerçek dünya koşullarının getirdiği belirsizlik ve değişkenlik faktörlerini hesaba katarak daha tutarlı bir model oluşturmayı amaçlamaktadır. Bu yaklaşım, modelimizin pratik uygulamalarda daha yüksek bir başarı oranına sahip olmasını sağlayacaktır.

Aşağıdaki Şekil 3.a 'da İnsansız Hava Aracının uçuş simülasyon arayüzünün bir ekran görüntüsüdür. Şekil 3.b 'de İHA tarafından alınan anlık nadir görüntü görülmekte olup, bu görüntüler İHA'nın konumlandırma sistemine doğrudan girdi olarak hizmet etmektedir. Şekil 3.c 'de ise, bu anlık görüntünün üzerinde gerçekleştirilen otokodlayıcı tabanlı sinir ağı işleminin sonuçları görülmektedir; burada görüntünün, özellik çıkarımı sonrasında elde edilen yüksek kontrastlı bir temsiliyi görmekteyiz. Şekil 3.d 'de, İHA'nın gerçekte uçtuğu coğrafi alanın haritası geniş bir




Şekil 3.13 Otokodlayıcı sinir ağı uygulanmış haritada İha'nın konumunun gösterimi. Sarı nokta tahmini yeşil nokta GPS verisiyle alınmış konumu göstermekte


perspektifte sunulmuş ve üzerinde İHA'nın konum tahminlerinin doğruluk durumları renk kodlayıcısıyla işaretlenmiştir.

Yeşil noktalar doğru tahmin edilen konumları, kırmızılar ise yanlış tahminleri temsil etmektedir. Şekil 3.e 'de, şablon eşleme algoritmasının uygulanmış olduğu, otokodlayıcı sinir ağıyla işlenmiş harita gösterilmektedir. Burada, kırmızı, yeşil, mavi kareler şablon eşlemeye verilmiş görüntü parçalarını göstermektedir. merkezdeki yeşil karenin 100 piksel yukarı ve solunda kırmızı kare yer almaktadır. 100 piksel sağ ve aşağısında da mavi kare yer almaktadır. Bu üç karenin kesişimi İHA'nın konumunu vermektedir






a) Performans testlerinde kullanılan simülasyonun arayüzü




b) İha'nın aldığı anlık nadir görüntü



c) Alınan nadir görüntünün otokodlayıcı sinir ağında işlendikten sonraki hali



d) Harita üzerinde İHA'nın rotasının gösterimi



e) Otokodlayıcı sinir ağır uygulanmış harita üzerinde İHA'nın rotasının gösterimi

Şekil 3.14 Testlerin gerçekleştirildiği simülasyon ekranı


İki Farklı Uydu Görüntüsü Kullanarak Konum Bulma Simülasyonu

Araştırma kapsamında, İnsansız Hava Aracının (İHA) anlık uçuş yeteneklerini simüle etmek için Python programlama dilinde geliştirilmiş Simulasyon 1 olarak adlandırılan bir simülasyon yazılımı kullanılmıştır. Yazılım, görüntü işleme ve matematiksel analizler için NumPy ve OpenCV (Zelinsky, 2009) gibi kütüphaneleri içermektedir.

Simülasyon sürecinde, 0.298 metre uzamsal çözünürlüğe ve 4 km x 4 km büyüklüğe sahip iki farklı uydu görüntüsü kullanılmıştır. Bu görüntüler, Google Earth ve Bing maps tarafından sağlanmış olup, simülasyonun gerçekçiliğini artırmak için seçilmiştir. Şekil 3.'a da gösterilen harita, İHA'nın uçuş yapacağı şehrin genel görünümünü simüle ederken, Şekil 3.b'de gösterilen ikinci harita nadir olarak alınacak anlık referans görüntüleri temsil etmektedir.

Şablon eşleme algoritması, Şekil 3.d'deki haritadan alınan 512x512 piksel boyutundaki görüntülerin, Şekil 3. c'deki haritada karşılık gelen konumlarını belirlemek için kullanılmıştır. Bu süreç 256 piksellik adımlarla gerçekleştirilmiş ve algoritmanın performansı, bu simülasyon aşamasında test edilmiştir.

Bu simülasyon sürecinin detaylı sonuçları ve elde edilen verilerin analizi "Bulgular ve Tartışma" bölümünde Çizelge 4.1 'de belirtilen sonuçlarla desteklenerek sunulmuştur.



Şekil 3.15 iki farklı uyduya ve zamana ait haritaların sinir ağı uygulanmadan önce ve sonra gösterimi

İki Farklı Uydu Görüntüsü Üzerinde Otonom Hareket Simülasyonu

Bu simülasyon, İHA'nın önceden belirlenmiş bir rota üzerindeki navigasyon kabiliyetini ve rotadaki belirlenen koordinat noktalarını ne derece etkin bir şekilde takip edebildiğini değerlendirmek amacıyla python programlama dili ile tasarlanmıştır ve Simulasyon 2 olarak adlandırılmıştır. Algoritmanın temel görevi, İHA'nın yolu takip edip etmediğini ve nihai hedef noktasına ulaşip ulaşmadığını doğrulamaktır.

Simülasyonun başlangıcında, birinci uydu görüntüsü bölgenin genel haritası olarak kabul edilirken, ikinci harita İHA'nın alacağı anlık nadir görüntüler için kullanılır. İHA'nın başlangıç konumu, ikinci harita üzerinde rastgele belirlenmiş 512 x 512 piksel büyüklüğünde bir alan olarak ayarlanır. İHA'nın navigasyon algoritması, bu başlangıç noktasından itibaren, birinci haritadaki

hedef koordinatlara doğru hareket etmeyi hedefler. Her hareket, mevcut x ve y koordinatları ile hedef koordinatlar arasındaki farka dayanır, böylece İHA hedefe en kısa yoldan ilerlemeyi amaçlar. İha her adımında 100 piksel yani harita üzerinde 29 metre hareket etmektedir.

Örneğin, İHA'nın güncel konumu (500, 1000) iken hedef (500, 1500) ise, İHA yalnızca y eksenini boyunca 500 piksel ilerleyecektir. İHA'nın her hareketi, x ve y koordinatlarındaki farklar temel alınarak hesaplanır ve İHA'nın konumu bu farklar azalana kadar güncellenir.

Şablon eşleme yöntemi, İHA'nın anlık görüntüsünü geniş bir harita üzerindeki karşılık gelen noktayı bulmak için kullanır. Bu yöntem, İHA'nın tahmini konumu ile hedef konumlarını sürekli karşılaştırarak, İHA'nın doğru yolu izleyip izlemediğini ve belirlenen hedeflere ulaşip ulaşmadığını belirler. Eğer İHA, istenen konuma 30 metreye kadar bir mesafeye ulaşmışsa, hedefe ulaştığı kabul edilir.

Algoritmanın başarıyla uygulanması, bilgisayarlı görme mekanizmaları ve görüntü işleme teknikleri kullanılarak sağlanır. Ayrıca, İHA'nın rotayı takip ederken karşılaşılabileceği engeller veya sapmalar, algoritma tarafından dikkate alınır. İHA'nın güzergahı ve hedef noktaları bu simülasyonun temel öğeleridir ve algoritmanın başarısını doğrudan etkiler.

Elde edilen bulgular ve gözlemler, "Bulgular ve Tartışma" bölümünde detaylı bir şekilde incelenmiştir, algoritmanın verimliliği, İHA'nın rotayı takip etme performansı ve hedeflere ulaşma başarısı üzerine bir analiz yapılmıştır.

Gerçek Dünya Verileri ile Sinir Ağı Modeli Performanslarının Değerlendirilmesi

Bu çalışmanın bu aşamasında gerçekleştirilen testler, İnsansız Hava Aracından elde edilen verilerle yapılandırılan kapsamlı bir performans analizini kapsamaktadır. Python programlama dili kullanılarak geliştirilen ve coğrafi bilgi sistemleri ile ilişkili 'gdal' ve 'rasterio' gibi kütüphaneleri ve görüntü işleme üzerine kullanılan opencv kütüphanesini entegre eden bu yazılım, 'Simülasyon 3' olarak adlandırılmıştır (Warmerdam, 2008). Bu simülasyonun temel hedefi, İHA sistemlerinin gerçek dünya senaryolarında görsel navigasyon yeteneklerinin doğrulanması ve bu yeteneklerin kapsamlı bir şekilde değerlendirilmesidir.

Bu simülasyon testinin amacı farklı otokodlayıcı sinir ağı modellerini test etmektir.

İlk olarak, İHA'nın kamerasından alınan görüntüler, manyetik yön bulma sensörü verisi kullanılarak coğrafi kuzey yönüne göre döndürülür. Bu işlem, görüntünün doğru bir şekilde yeryüzü ile hizalanmasını sağlar ve navigasyon sürecindeki yön bulma hassasiyetini artırır. Ardından, İHA'nın irtifa bilgileri esas alınarak görüntülerin uzamsal çözünürlüğü 0.298 metre olacak şekilde ayarlanır. Bu çözünürlük ayarı, görüntü üzerindeki nesnelerin gerçek boyutlarının doğru bir şekilde temsil edilmesini ve şablon eşleme algoritmasının etkin çalışmasını sağlamak için kritik öneme sahiptir.

Şablon eşleme işlemi, geniş bir coğrafi alandaki uydu haritasının 10000x10000 piksellik bir bölümü üzerinde gerçekleştirilir. Bu bölümün seçilmesi, İHA'nın o anki konumunu temsil eden bir

alanı odaklamak içindir. İHA'nın konumu, 30 metrelik bir hata payı ile doğru kabul edilen bir alan içinde belirlenirse, bu konum doğru olarak kaydedilir. Her yeni görüntü alındığında, 10000x10000 piksellik harita parçası İHA'nın güncel konumuna göre yeniden merkezlenir ve şablon eşleme işlemi tekrarlanır.

Bu simülasyon sürecinde, algoritmanın ne kadar doğru ve güvenilir çalıştığını anlamak için çeşitli performans ölçütleri kullanılır. Kök Ortalama Kare Hatası (RMSE), Ortalama Mutlak Hata (MAE), standart sapma ve F1 skoru gibi istatistiksel değerler, algoritmanın tahminlerinin doğruluğunu ve karşılaştırılabilirliğini belirlemede yardımcı olur. Bu değerlerin belirlenmesi, algoritmanın başarımını sayısal olarak değerlendirmeye ve geliştirilmesi gereken alanları tespit etmeye yarar.

Sonuç itibarıyla, Simülasyon 3, İHA'nın görsel navigasyon sistemlerinin gerçek zamanlı uçuş verileriyle nasıl çalıştığını deneme ve doğrulama fırsatı sunar. Bu simülasyon, İHA sistemlerinin gerçek dünya koşullarındaki performansını ve bu koşullara ne derece uyum sağlayabileceğini değerlendirme açısından önemli bir adımdır.

İleri Düzey Simülasyon Üzerinden Gerçek Uçuş Rotası Testleri

Python programlama dili kullanılarak yürütülen bu testler simülasyon 4 olarak adlandırılmıştır. Bu testler, İHA sistemlerinin navigasyon ve konum doğrulama kabiliyetlerini kapsamlı bir şekilde değerlendiren, gerçek zamanlı ve çeşitli ortamlarda gerçekleştirilmiş 11 ayrı uçuşu içermektedir. Bu uçuşlar, şehir ve arazi alanlarında gerçekleştirilmiş olup, İHA'nın farklı coğrafi ve çevresel koşullara nasıl uyum sağladığını test etmeyi amaçlamaktadır. Her bir uçuş testi, İHA'nın başlangıçtan bitiş noktasına kadar olan güzergahtaki performansını detaylı bir şekilde incelemektedir.

İlk olarak, İHA'nın aldığı her nadir görüntü, manyetik yön bulma sensörü verileri kullanılarak kuzey yönüne göre döndürülerek yeryüzü ile doğru hizalanması sağlanır. Ardından, İHA'nın irtifa bilgilerine dayanarak, görüntülerin uzamsal çözünürlüğü 0.298 metre/piksel değerine ayarlanır. Bu ön işlemler, görüntü üzerindeki nesnelerin doğru boyut ve oryantasyon ile temsil edilmesini sağlamakta ve şablon eşleme sürecinin doğruluğunu artırmaktadır.


Şablon eşleme işlemi, bölgenin geniş ölçekli haritasından 2000x2000 piksellik bir görüntü parçası alınarak başlar. İHA'nın başlangıç konumu, bu görüntü parçasının merkezine yerleştirilir. Daha sonra, İHA tarafından alınan ve otokodlayıcı sinir ağı ile işlenmiş olan 544x544 piksellik görüntüler, x ve y koordinatlarında 100 piksel aralıklı üç ayrı görüntü olarak elde edilir. Bu görüntüler, evrişimli sinir ağlarının kenar bozulmalarını önlemek amacıyla, dört kenarından 16'şar piksel kesilerek 512x512 piksele indirgenir.

Normalize Edilmiş Çapraz Korelasyon Katsayısı kullanılarak gerçekleştirilen şablon eşleme işlemi, bu 512x512'lik görüntülerin İHA'nın anlık konumunu belirlemek için kullanılır. Üç farklı görüntünün kesişim noktaları belirlenir ve bu kesişimlerin merkezi, İHA'nın anlık konumu olarak

kabul edilir. Eger iki görüntü kesişiyorsa, bu iki görüntünün kesişim noktasının ortası anlık konum olarak değerlendirilir. Kesişim olmaması durumunda, harita parçası her defasında 250 piksel genişletilerek şablon eşleme işlemi tekrarlanır. Bu süreç, konum tespiti başarılı olana kadar devam eder ve konum başarıyla tespit edildiğinde, harita parçası tekrar 2000x2000 piksel boyutuna dönüştürülür.

Her bir uçuş testi sırasında, Kök Ortalama Kare Hatası (RMSE), Ortalama Mutlak Hata (MAE), standart sapma ve F1 skoru gibi istatistiksel metrikler ayrı ayrı hesaplanmıştır. Bu metrikler, her uçuş için algoritmanın tahmin başarısını ve doğruluğunu objektif bir şekilde değerlendirmekte ve algoritmanın performansının kantitatif analizini sağlamaktadır.

Bu modelleme, İHA'nın başlangıç konumundan bitiş noktasına kadar olan güzergahta, kaybolmadan doğru konumları bulma kabiliyetini test etmekte ve İHA sistemlerinin çeşitli ortamlarda nasıl performans gösterdiğini ortaya koymaktadır. Şekil 3.'te arayüzü gösterilen bu simülasyon, şehir ve arazi gibi farklı coğrafi alanlarda İHA'nın yol takibi ve konum tespiti konusundaki güvenilirliğini ve adaptasyon kabiliyetini artırmak için potansiyel iyileştirmeleri belirleme yönünde değerli veriler sunmaktadır.



Şekil 3.16 Gerçek uçuş rotası takip edilen simülasyonun ekran görüntüsü

4. BULGULAR VE TARTIŞMA

Bu bölüm, araştırmada yürütülen dört farklı simülasyon testinin bulgularını ve bunların analizini içermektedir. Her bir simülasyon ve modelleme, İnsansız Hava Aracı (İHA) sistemlerinin görsel navigasyon kabiliyetlerini artırmaya yönelik belirli bir yönü veya parametreyi test etmek amacıyla tasarlanmıştır. Sonuçlar, sistemlerin performansını değerlendirmede ve en uygun yapılandırmaları tespit etmede kritik öneme sahiptir. Ayrıca, bu testler aracılığıyla elde edilen veriler, uygulamalı görsel navigasyon sistemlerinin geliştirilmesine yönelik derinlemesine anlayış kazanmamızı sağlamaktadır.

4.1. Simülasyon ve Modellemeler

Simülasyonlar ve modellemeler kapsamında, farklı model yapılandırmalarının, aktivasyon fonksiyonlarının ve ağ mimarilerinin etkileri deneysel olarak incelenmiştir. Her simülasyon, önceden tanımlanmış metrikler bazında modellerin performansını ölçmek ve karşılaştırmak için tasarlanmıştır. İlk iki simülasyon anlık nadir görüntü olarak 0.298 metre uzamsal çözünürlükteki uydu verileri kullanılırken, son iki simülasyonda gerçek İHA görüntüleri kullanılmıştır.

4.1.1. İki Farklı Uydu Görüntüsü Kullanarak Konum Bulma Simülasyonu:

Araştırmanın bu bölümü, geniş kapsamlı bir deneysel çalışmanın sonuçlarını sunmaktadır. Yaklaşık 4000 sinir ağı modeli, belirlenen performans kriterlerine göre değerlendirilmiş ve en başarılı bulunan 30 model bu analizde detaylandırılmıştır. Bu modeller, bant sayısı, kernel boyutu, aktivasyon fonksiyonu ve adım gibi çeşitli parametreler açısından farklılaşmaktadır. Sunulan Çizelge 4.1, seçilen bu modellerin performans karşılaştırmasını göstermekte olup, modelin doğru tahmin sayısını, yanlış tahmin sayısını ve genel başarı oranını içermektedir.

Çizelge 4.1 Test sürecinde kullanılan otokodlayıcı sinir ağı modelleri ve başarı yüzdeleri

Sıra	Model Adı	Bant Sayısı	Kernel Boyutu	Aktivasyon Fonksiyonu	Adım	Doğru Tahmin	Yanlış Tahmin	Başarı Oranı
1	Model_1	32	3	ELU	(2,2)	2535	274	90.26%
2	Model_2	64	3	ELU	(2,2)	2465	344	87.75%
3	Model_3	64	3	ELU	(1,1)	2630	179	93.63%
4	Model_4	48	5	ELU	(2,2)	2530	279	90.07%
5	Model_5	32	3	ELU	(1,1)	2532	277	90.15%
6	Model_6	48	5	ELU	(2,2)	2542	267	90.48%
7	Model_7	48	5	ELU	(2,2)	2532	277	90.15%
8	Model_8	64	3	ELU	(1,1)	2569	240	91.44%
9	Model_9	32	5	ELU	(2,2)	2412	397	85.86%
10	Model_10	32	5	ELU	(2,2)	2534	275	90.19%
11	Model_11	32	3	ELU	(1,1)	2489	320	88.62%
12	Model_12	32	6	ELU	(2,2)	2455	354	87.40%

Çizelge 4.1'in Devamı

13	Model_13	64	3	ELU	(1,1)	2400	409	85.42%
14	Model_14	64	3	ELU	(1,1)	2459	351	87.52%
15	Model_15	64	3	ELU	(1,1)	2510	299	89.36%
16	Model_16	24	5	ELU	(1,1)	2495	314	88.82%
17	Model_17	48	4	ELU	(1,1)	2446	363	87.07%
18	Model_18	48	7	ELU	(1,1)	2405	404	85.61%
19	Model_19	64	3	ELU	(2,2)	2352	457	83.72%
20	Model_20	32	5	ELU	(2,2)	2262	547	80.54%
21	Model_21	40	5	ELU	(1,1)	2264	545	80.61%
22	Model_22	64	3	ELU	(2,2)	2373	436	84.47%
23	Model_23	32	3	ELU	(1,1)	2399	410	85.39%
24	Model_24	40	3	ELU	(1,1)	2241	568	79.77%
25	Model_25	32	5	ELU	(1,1)	2322	487	82.65%
26	Model_26	32	2	ELU	(1,1)	2296	513	81.75%
27	Model_27	32	3	ELU	(2,2)	2210	599	78.69%
28	Model_28	32	3	ELU	(1,1)	2238	571	79.68%
29	Model_29	64	3	ELU	(1,1)	2218	591	78.97%
30	Model_30	32	7	ELU	(2,2)	2206	603	78.53%

Model_3, %93.63 başarı oranı ile bu grubun en yüksek performansını gösterirken, Model_30 ise %78.53 ile en düşük başarı oranına sahip model olmuştur. Bu sonuçlar, bant sayısı ve kernel boyutunun doğru tahmin sayısında belirgin bir etkiye sahip olduğunu ve yanlış tahmin sayısı üzerinde de önemli farklılıklar yarattığını göstermektedir.

Aktivasyon fonksiyonu olarak ELU'nun (Exponential Linear Unit) kullanılması, modeller arasında tutarlı sonuçlar sağlamış ve adım değeri (2,2) genel standart olarak benimsenmiştir. Tabloda yer alan bu modellerin detaylı analizi, uydu görüntü işlemede kullanılan derin öğrenme modellerinin iyileştirilmesi için kritik içgörüler sunmaktadır.

En yüksek performans gösteren bu 30 modelin seçilmesi, araştırmanın geniş kapsamını ve derinliğini göstermektedir. Bu modellerin başarısı, test edilen geniş model yelpazesinin en üst dilimini temsil etmektedir.

4.1.2. İki Farklı Uydu Görüntüsü Üzerinde Otonom Hareket Simülasyonu

Simülasyon 2'nin sonuçları, farklı sinir ağı modellerinin Ürgüp haritası üzerinde belirlenen 20 hedef noktasına ulaşım kapasitelerini değerlendirmektedir. Toplam 30 modelin analiz edildiği bu testler, modellerin büyük çoğunluğunun hedefleri başarıyla tamamladığını ortaya koymuştur. Ulaşılan hedef sayısı ile ulaşım adımları arasındaki korelasyon, modellerin etkinliği hakkında kıymetli bilgiler sunmaktadır.

Çizelge 4.2

'te sunulan verilere göre, Model 1, Model 10, Model 13, Model 15, Model 16 ve Model 5 gibi modeller, tüm hedefleri başarıyla geçerek en etkin performansı sergilemişlerdir. Bu modellerin

ulařım adımları 95 ile 100 arasında deęiřmekte olup, nihai hedeflere ulařım aısından ysek bir verimlilik gsterdikleri tespit edilmiřtir. Dięer yandan, Model 17, Model 20, Model 21, Model 22, Model 25 ve Model 26 gibi modellerin hedef geme oranları greceli olarak dřk kalmıř ve bu modeller nihai hedeflere ulařamamıřlardır.

izelge 4.2 Modelleme zerinde belirlenen hedeflerin performans sonuları

Model Adı	Harita	Toplam Hedef Sayısı	Bařarıyla Geilen Hedef Sayısı	Ulařım adımı	Nihai Hedefe Ulařıldı mı?
Model 1	rgp	20	20	98	Evet
Model 10	rgp	20	20	100	Evet
Model 15	rgp	20	20	97	Evet
Model 5	rgp	20	20	95	Evet
Model 13	rgp	20	19	102	Evet
Model 16	rgp	20	19	95	Evet
Model 3	rgp	20	19	103	Evet
Model 30	rgp	20	19	90	Evet
Model 2	rgp	20	18	110	Evet
Model 8	rgp	20	18	105	Evet
Model 11	rgp	20	17	112	Evet
Model 4	rgp	20	17	115	Evet
Model 12	rgp	20	16	117	Evet
Model 18	rgp	20	16	91	Evet
Model 6	rgp	20	16	120	Evet
Model 14	rgp	20	15	124	Evet
Model 19	rgp	20	15	107	Evet
Model 7	rgp	20	15	125	Evet
Model 23	rgp	20	14	110	Evet
Model 9	rgp	20	14	130	Evet
Model 24	rgp	20	13	93	Evet
Model 29	rgp	20	13	102	Evet
Model 28	rgp	20	12	89	Evet
Model 21	rgp	20	11	117	Hayır
Model 26	rgp	20	11	102	Hayır
Model 20	rgp	20	9	105	Hayır
Model 25	rgp	20	8	86	Hayır
Model 17	rgp	20	5	94	Hayır
Model 22	rgp	20	5	89	Hayır
Model 27	rgp	20	5	112	Hayır

zellikle Model 17'de gzlemlenen dřk hedef geme sayısı ve nihai hedefe ulařmama durumu, otokodlayıcı sinir aęının grnt iřleme kapasitesindeki eksikliklere iřaret edebilir. Bu, belirli kořullar altında model parametrelerinin yetersiz kaldıęının veya harita verisinin modeller tarafından doęru iřlenemedięinin bir gstergesi olabilir.

Sonuç itibarıyla, Simülasyon 2, farklı modellerin performanslarının değerlendirilmesi ve iyileştirilmesi yönünde kritik bilgiler sağlamaktadır. Başarıyla geçilen hedef sayısı ve nihai hedefe ulaşım durumu, model tercihlerinin ve rotayı takip etme stratejilerinin önemini gözler önüne sermektedir.

Simülasyon 3 ve 4 ise, gerçek İHA uçuş verileri ile gerçekleştirilmiş olup, İHA sistemlerinin gerçek operasyonel koşullarda karşılaşılabileceği zorluklara dair daha somut veriler sunmaktadır. Simülasyon 2'nin ana amacı, gerçek dünya senaryolarında sinir ağı parametrelerinin seçimine yardımcı olmak ve bu parametrelerin etkinliğini doğrulamaktır.

4.1.3. Gerçek Dünya Verileri ile Sinir Ağı Model Performanslarının Değerlendirilmesi

Simülasyon 3 kapsamında gerçekleştirilen performans değerlendirme testlerinin detaylı analizi, otokodlayıcı tabanlı sinir ağı modellerinin gerçek dünya koşullarında gösterdiği performansı aydınlatmaktadır. Analizde dikkate alınan çeşitli model yapılandırmalarının sonuçları Çizelge 4.3'te sunulmuştur ve bu sonuçlar, görsel navigasyon sistemlerinin etkinliğini ve güvenilirliğini sayısal olarak doğrulamaktadır.

Model_4'ün 990 doğru tahmin ile 0.9844'luk f1 skoru elde etmesi, modelin yüksek doğruluk ve güvenilirlik seviyesine işaret etmektedir. Öte yandan, model_2 ve model_6 gibi modeller de benzer şekilde yüksek performans göstermiş ve yaklaşık %98'e varan doğruluk oranları ile f1 skorlarında 0.982'ye ulaşmışlardır. Bu sonuçlar, modellerin gerçek zamanlı navigasyon görevlerinde güçlü potansiyellerini ve kararlılıklarını göstermektedir.

Analiz edilen tüm modeller arasında, doğru tahmin sayısı ve doğru pozitif oranları dikkate alındığında, genel olarak model_4, model_2 ve model_6 öne çıkmıştır. Bu modeller, düşük RMSE ve MAE değerleri ile yüksek f1 skorlarına ulaşarak, karmaşık şehir ortamlarında İHA navigasyonunda etkin bir performans sergilemişlerdir. Ancak, model_13 gibi bazı modellerin performansı, özellikle yanlış tahmin sayısının artışı ve daha yüksek RMSE değerleri ile daha düşük f1 skorlarına işaret ederek göreceli olarak daha az tatmin edici sonuçlar sergilemiştir.

Siyah beyaz (grayscale) işleme sonuçları da otokodlayıcı sinir ağı modelinin kullanılmadığı durumlarda elde edilmiş ve bu durum, sinir ağı tabanlı işlemenin önemini açıkça ortaya koymuştur. Sinir ağı modeli kullanılmadan sadece siyah beyaz hale getirilen görüntü ve haritalarla gerçekleştirilen testlerde, sistem doğruluğunda ve f1 skorunda ciddi bir düşüş gözlemlenmiştir. Bu, sinir ağı tabanlı modellerin, görüntüdeki karmaşıklıkları algılamada ve doğru konum tahminleri yapmada, yalnızca piksel yoğunluğuna dayanan yaklaşımlara göre ne derece üstün olduğunun bir göstergesidir. Modelin kullanılmadığı durum, algoritmanın çevresel detayları algılamasında ve hassas tahminler yapabilmesinde kritik bir eksiklik olarak ortaya çıkmakta, bu ise otokodlayıcı sinir ağı modellerinin, görsel navigasyon sistemlerinin etkinliğini artırmadaki rolünün altını çizmektedir.

Sonuç olarak, Çizelge 4.3'te sunulan verilerin genel değerlendirmesi, otokodlayıcı tabanlı sinir ağı modellerinin şehirsel ortamlarda İHA navigasyonu için güçlü ve güvenilir araçlar olduğunu

teyit etmektedir. Elde edilen sonuçlar, gelecekteki araştırmalara ve uygulamalara, İHA sistemlerinin şehirsel ortamlardaki navigasyon performansını artırmak için değerli içgörüler ve metodolojik bir çerçeve sunmaktadır. Yanlış tahminlerin analizi ve bu tahminlerin nedenlerinin derinlemesine incelenmesi, bu modellerin geliştirilmesi ve iyileştirilmesi için önemli bir adım olarak kabul edilmektedir.

Çizelge 4.3 otokodlayıcı modellerin performans sonuçları

No	RMSE Değeri:	MAE Değeri:	Standart Sapma Değeri:	Doğru Pozitif	Yanlış Pozitif	Doğru Negatif	Yanlış Negatif	F1 Skoru
Model_4	0.1209	0.0414	0.1136	984	25	35	6	0.984
Model_6	0.1215	0.0386	0.1152	983	29	34	4	0.983
Model_2	0.1233	0.0397	0.1167	979	28	35	8	0.982
Model_1	0.1199	0.0403	0.1129	963	44	38	5	0.975
Model_5	0.1503	0.0523	0.1410	942	45	53	10	0.972
Model_3	0.1233	0.0435	0.1153	947	61	34	8	0.965
Model_10	0.1761	0.0683	0.1623	898	67	75	10	0.959
Model_18	0.1746	0.0676	0.1610	908	72	60	10	0.957
Model_17	0.1883	0.0736	0.1733	892	70	76	12	0.956
Model_11	0.1751	0.0659	0.1622	904	72	62	12	0.956
Model_12	0.1614	0.0617	0.1492	898	66	65	21	0.954
Model_16	0.1800	0.0720	0.1650	884	77	74	15	0.951
Model_30	0.2122	0.0920	0.1913	851	79	106	14	0.948
Model_26	0.2211	0.0979	0.1982	832	98	106	14	0.937
Model_21	0.1995	0.0837	0.1811	855	99	78	18	0.936
Model_24	0.2206	0.0949	0.1991	836	104	98	12	0.935
Model_25	0.2069	0.0916	0.1856	828	98	107	17	0.935
Model_20	0.2075	0.0870	0.1884	856	106	74	14	0.934
Model_27	0.2290	0.1030	0.2045	815	112	107	16	0.927
Model_8	0.2371	0.1118	0.2090	795	110	129	16	0.927
Model_6	0.2166	0.0955	0.1944	806	114	110	20	0.923
Model_15	0.2276	0.1048	0.2021	797	119	114	20	0.920
Model_28	0.2499	0.1218	0.2182	774	126	138	12	0.918
Model_9	0.2443	0.1156	0.2152	781	133	117	19	0.911
Model_7	0.2678	0.1337	0.2321	757	142	132	19	0.904
Model_14	0.2475	0.1221	0.2153	760	140	125	25	0.902
Model_19	0.2581	0.1288	0.2237	749	147	138	16	0.902
Model_22	0.2672	0.1359	0.2301	740	151	141	18	0.898
Model_23	0.2717	0.1397	0.2332	731	155	144	19	0.894
Model_13	0.2762	0.1435	0.2362	723	160	148	19	0.890
Siyahbyeaz (Grayscale)	0.2614	0.1594	0.2071	502	274	229	47	0.758

4.1.4. İleri Düzey Simülasyon Üzerinden Gerçek Uçuş Rotası Testleri

Bu araştırmanın ileri safhasında, İHA'nın navigasyon yetkinliklerini mümkün olan en geniş spektrumda sınamak üzere, şehir merkezleri ve doğal araziler üzerinde on bir ayrı gerçek uçuş testi gerçekleştirilmiştir. Bu testler, Python programlama dilinin gücünden yararlanarak geliştirilen ve gerçek zamanlı operasyonel verilere uyum sağlayacak şekilde optimize edilmiş konum tespiti simülasyonumuzun sonuçlarını sergilemektedir.

Şehir Alanları Üzerinde Gerçekleştirilen Uçuş Testleri

Bu çalışma kapsamında şehir alanları üzerinde gerçekleştirilen her bir İHA uçuş testi, algoritmanın tahmin başarısını ve gerçek dünya koşullarındaki performansını değerlendirmek amacıyla detaylı bir analiz sürecinden geçirilmiştir. İHA'nın uçuş rotası, şekillerde yeşil bir çizgiyle gösterilmiş, algoritmanın coğrafi konum tahminleri ise sarı noktalarla işaretlenmiştir. Bu görselleştirmeler, algoritmanın tahmin etkinliğinin ve gerçek dünya verileriyle olan uyumunun kritik bir analizini sunar ve böylece algoritmanın doğruluğu somut bir biçimde gözler önüne serilir.

Analiz sürecinde, algoritmanın performansını sayısal olarak değerlendirmek için Root Mean Square Error (RMSE), Mean Absolute Error (MAE), standart sapma ve F1 skoru gibi istatistiksel metrikler hesaplanmıştır. Bu metrikler, algoritmanın tahminlerinin gerçek değerlere ne kadar yakın olduğunu ve tahmin sonuçlarının ne derece tutarlı olduğunu objektif bir şekilde ortaya koymak için kritik öneme sahiptir. İHA'nın uçuş güzergahı boyunca elde edilen nadir görüntülerin, algoritmanın tahminleriyle ne kadar örtüştüğü bu ölçümler sayesinde nicel bir temele oturtulmuş ve algoritmanın genel performansı hakkında sağlam bir değerlendirme yapılmıştır. Sonuç olarak, bu analizler algoritmanın şehirsiz ortamlarda gösterdiği etkinliği ve adaptasyon kabiliyetini somut bir şekilde ortaya koymuş, gelecekteki iyileştirmeler için önemli veriler sunmuştur.

Uçuş 1


Şekil 4.1'de sunulan ve 20 Ağustos 2022 tarihinde 18:32-18:46 saat aralığında, havanın açık olduğu ama güneşin batmaya yakın olmasında dolayı gölgelerin belirginleştiği bir saatte gerçekleştirilen şehir güzergahı üzerindeki İHA uçuşu sırasında toplamda 147 nadir görüntü elde edilmiştir. Şehirsiz alandaki bu uçuş testinin performansı, şehirsiz coğrafyanın getirdiği görsel karmaşıklığa rağmen özellikle kayda değer bulunmuştur. Elde edilen 147 tahminin 138'inin doğrulukla eşleşmesi, modelin %93.88'lik bir doğruluk oranı sergilediğini ortaya koymaktadır; bu oran, özellikle şehirsiz ortamların yarattığı görsel karmaşıklıkla başa çıkma kapasitesinin bir kanıtı olarak değerlendirilebilir.

Hesaplanan Kök Ortalama Kare Hata (RMSE) 0.126 değeri, modelin tahminlerinin gerçek değerlere olan yakınlığını ve bu tahminlerin güvenilirliğini yansıtmaktadır. Düşük RMSE değeri, modelin tahminlerinin gerçek konumlara oldukça yakın olduğunu ve bu nedenle yüksek bir doğruluk düzeyine işaret ettiğini göstermektedir.

Ortalama Mutlak Hata (MAE) değeri 0.056 olarak ölçülmüştür; bu değer, modelin tahminlerindeki ortalama mutlak hata miktarını yansıtarak, genel olarak modelin ne derece güvenilir sonuçlar ürettiğini gösterir. Elde edilen düşük MAE değeri, modelin tutarlı ve güvenilir tahminler sağladığını ortaya koymaktadır.

Standart sapma 0.112 değeri, tahminlerin dağılımını ve modelin farklı uçuş koşulları ve görüntü özellikleri arasında gösterdiği performans tutarlılığını belirtir. Modelin tahminlerinin kararlı bir dağılım sergilediği ve farklı senaryolarda güvenilir sonuçlar verdiği anlaşılmaktadır.

F1 skoru ise 0.982 olarak hesaplanmıştır ve bu, modelin doğru pozitif tahminler ile yanlış negatif tahminler arasında denge kurma yeteneğini gösterir. Yüksek F1 skoru, modelin şehrsel alanlardaki konum tespitinde hem hassasiyet hem de kesinlik açısından üstün bir performans sergilediğini belirtir. Yanlış tahminlerin analizi, tüm yanlış pozitif tahminlerin şehrsel olmayan arazi alanlarında yapıldığını göstermiştir, bu da otokodlayıcı sinir ağının eğitim verileri göz önünde bulundurulduğunda beklenen bir sonuçtur.



Şekil 4.1 Şehir Üzerindeki Uçuş Rotası ve Görüntülenen Konumlar — Yeşil ok, İnsansız Hava Aracı (İHA) tarafından izlenen GPS güzergahını göstermektedir. Sarı noktalar ise kullandığımız önerilen modelin tahminlerini temsil etmektedir.


Uçuş 2

Şekil 4.2’de 22 Ağustos 2022 tarihinde 14:08-14:09 saat aralığında güneşli ve görüş mesafesi yüksek ve açık bir havada gerçekleştirilen ikinci uçuş sırasında, İHA'nın alınan 200 nadir görüntüsü üzerinden yapılan detaylı bir analiz sunulmaktadır. Şehirsel alanda yürütülen bu uçuş testinde, kullanılan sinir ağı modeli, yol boyunca İHA'nın tüm konumlarını hatasız bir şekilde tespit edebilmiştir. Bu, Şekil 4.2 'da sarı dairelerle temsil edilen İHA konumlarının, geliştirilmiş model aracılığıyla %100 doğrulukla tahmin edildiğini gösterir.

Geliştirilen model, RMSE değeri 0.022 ile tahminlerin gerçek değerlerden olan sapmasını son derece düşük bir seviyede tutmuş ve böylelikle yüksek düzeyde doğruluk sergilemiştir. MAE değeri olan 0.021, modelin tahminlerindeki ortalama hata miktarının minimal düzeyde olduğunu göstermektedir ve bu da modelin ürettiği konum tahminlerinin gerçek değerlere yakın olduğunu altını çizmektedir.

Standart sapma değeri 0.004, modelin tahminlerindeki dağılımın dar olduğunu ve son derece tutarlı sonuçlar ürettiğini işaret eder. Bu düşük varyasyon, modelin çeşitli uçuş koşullarında kararlı ve güvenilir performans gösterdiğini göstermektedir.

En dikkate değer bulgu, F1 skorunun 1 olarak hesaplanmış olmasıdır. Bu mükemmel skor, modelin hem kesinlik (doğru pozitiflerin yanlış pozitiflere oranı) hem de duyarlılık (doğru pozitiflerin gerçek pozitiflere oranı) açısından kusursuz bir performans sergilediğini belirtir. Modelin yanlış negatif tahmin yapmaması, algoritmanın bu şehirsel güzergahta tam bir doğrulukla konum belirleme kapasitesine sahip olduğunu kanıtlar.




Şekil 4.2 Şehir Üzerindeki Uçuş Rotası ve Görüntülenen Konumlar

Uçuş 3

22 Ağustos 2022 tarihinde 14:27-14:40 saatleri arasında güneşli ve görüş mesafesi yüksek ve açık bir havada Şekil 4.3'da gösterilen rota üzerinde gerçekleştirilen üçüncü uçuş sırasında toplanan 210 nadir görüntü üzerinden yürütülen analiz, İHA'nın navigasyon algoritmasının şehrsel ortamlarda konum doğrulama yeteneğini detaylı bir biçimde değerlendirmiştir. Geliştirilen sinir ağı modeli, şablon eşleştirme yöntemiyle bu konumların 206'sını başarıyla ve doğru bir şekilde tespit etmiştir, bu da modelin %98.1'lik bir doğruluk oranı sergilediğini gösterir ve algoritmanın doğruluk oranını gözle görülür bir şekilde yükseltmektedir.

Elde edilen RMSE değeri 0.067, modelin tahminlerinin gerçek değerlerden olan sapmasını düşük bir seviyede tuttuğunu ve son derece doğru sonuçlar verdiğini göstermektedir. Ortalama Mutlak Hata (MAE) değeri 0.032 ile, modelin tahminlerindeki ortalama hata miktarının oldukça düşük olduğunu ve tahminlerin genellikle gerçek konumlara yakın olduğunu göstermektedir.

Standart sapma 0.059 ile modelin tahminlerindeki tutarlılığını ve dağılımının dar olduğunu işaret eder, bu da modelin farklı senaryolar ve görüntü özellikleri arasında kararlı sonuçlar ürettiğini



Şekil 4.4 2 Mayıs 2023'te alınan 181 görüntü için konum tahminleri. Şehir koşullarında %86.7 doğruluk oranı gösterilmektedir.

F1 skoru 0.952 olarak hesaplanmış olup, bu değer modelin kesinlik ve duyarlılık açısından mükemmele yakın bir performans sergilediğini gösterir. Yanlış pozitiflerin azlığı ve yüksek doğru negatif sayısı, modelin özellikle şehrsel ortamlarda güçlü bir konum tespiti yeteneğine sahip olduğunu belirtir. Bununla birlikte, yanlış tahminlerin ağırlıklı olarak arazi alanlarında gerçekleşmesi, modelin eğitim veri setindeki şehrsel ağırlığı yansıtmakta ve bu durum, modelin şehir dışı koşullara adaptasyonu için potansiyel iyileştirme alanlarına işaret etmektedir.


Uçuş 5

14.04.2023 tarihinde 13:58 – 14-16 saat aralığında güneşli bir günde ve gölgelerin oldukça kısa olduğu bir zaman diliminde gerçekleştirilen ve Şekil 4.5'da sunulan şehir güzergahı üzerinden alınan 237 nadir görüntü üzerinde yapılan analiz, İHA'nın navigasyon algoritmasının şehrsel ortamda konum tespiti yeteneğini etkileyici bir düzeyde sergilemiştir. İHA'nın algoritma tarafından tahmin edilen konumları, evrişimli otokodlayıcı sinir ağı modeli kullanılarak işlenmiş ve şablon eşleştirme algoritmasıyla değerlendirilmiştir.

Bu uçuş testi sonuçlarına göre, modelin %96.63'üne denk gelen 229 doğru tahminle, sunulan görüntülerin büyük çoğunluğunu başarıyla doğruladığı ortaya çıkmıştır. Bu, algoritmanın şehrsel çevredeki karmaşık görsel öğeler arasında etkin bir şekilde navigasyon yapabilme kapasitesini göstermektedir.

Modelin performansını değerlendiren istatistiksel metrikler, RMSE değerinin 0.112 olarak ölçülmesiyle, modelin tahminlerinin gerçek değerlere oldukça yakın olduğunu ve önemli bir doğrulukla konum tespiti yaptığını ifade etmektedir. Ortalama Mutlak Hata (MAE) değeri 0.032 ile, modelin tahminlerindeki ortalama sapmanın düşük olduğunu ve böylece tahminlerin genellikle gerçek konumlara yakın olduğunu gösterir. Standart sapma 0.107 ise, modelin tahminlerinin ne derece tutarlı olduğunu ve tahminler arasındaki değişkenliğin sınırlı olduğunu belirtir, bu da modelin güvenilir ve kararlı çıktılar ürettiğini kanıtlar.

Özellikle kayda değer olan yüksek F1 skoru 0.995, modelin kesinlik ve duyarlılık açısından iyi bir performans sergilediğini vurgulamaktadır. Doğru pozitif tahminlerin çok yüksek olması ve yanlış negatif tahminlerin minimal düzeyde olması, algoritmanın şehrsel ortamlarda güvenilir navigasyon sağlama kapasitesinin altını çizmektedir.




Şekil 4.5 5. Şehir alanı test uçuşu rotası

Uçuş 6

Şekil 4.6'de belirtilen ve 14:20 – 14:31 saat aralığında güneşli bir günde ve gölgelerin oldukça kısa olduğu bir zaman diliminde gerçekleştirilen altıncı uçuş sırasında, evrişimli otokodlayıcı sinir ağı temelli algoritmanın navigasyon doğruluğu, toplanan 147 nadir görüntü üzerinden hiçbir yanlış konum belirleme olmadan tam bir kesinlikle değerlendirilmiştir. Uçuş güzergahı üzerinden gerçekleştirilen yer tespiti analizinde, algoritma görüntülerin tamamında İHA'nın konumunu %100 doğruluk oranıyla tespit etmiştir.

Modelin performansını değerlendiren kritik istatistiksel ölçütler, modelin RMSE değerinin 0.016 olarak ölçülmesiyle, tahminlerin gerçek konumdan oldukça düşük bir sapma gösterdiğini ve bu nedenle yüksek derecede doğruluk sağladığını işaret etmektedir. Ortalama Mutlak Hata (MAE) 0.0142 ile tahminlerin ortalama hata miktarının minimal olduğunu ve bu düşük MAE değeri, modelin tahminlerinde yüksek bir kesinlik sergilediğini gösterir. Standart sapma 0.008, modelin tahminlerinin ne derecede tutarlı olduğunu ve tahminler arasındaki varyansın sınırlı olduğunu yansıtarak, modelin güvenilir ve kararlı çıktılar ürettiğini kanıtlamaktadır.



Şekil 4.6 6. Test uçuşu rotası gösterimi


Ayrıca, F1 skoru 1.0 olarak hesaplanarak, modelin doğru pozitif tahminlerde mükemmel bir performans sergilediğini ve yanlış negatif tahminlerin olmadığını ortaya koyar. Bu, algoritmanın, kentsel ortamlardaki potansiyel navigasyon zorluklarını başarıyla aşabilme kapasitesinin güçlü bir göstergesidir.

Uçuş 7

Şekil 4.7'de gösterilen, 14 Nisan 2023 tarihinde ve 14:33– 14:43 saat aralığında güneşli bir günde ve kentsel ortamda icra edilen yedinci uçuş testinde, yapay zekâ tabanlı navigasyon algoritması, belirlenen rotada toplanan 172 görüntü üzerinden 158 adet doğru İHA konum tahmini gerçekleştirmiştir. Bu sonuçlar, toplam alınan görüntü sayısına oranla %91.86'lık bir doğruluk oranını ifade eder ve algoritmanın kentsel çevredeki navigasyon performansının üst düzey olduğunu göstermektedir.

Performans metrikleri çerçevesinde, RMSE değeri 0.120 ile tahminlerin gerçek konumlarla olan ortalama karelerinin kökünün değerini, yani tahmin edilen konumların gerçek değerlerden ne ölçüde sapma gösterdiğinin bir göstergesini temsil eder ve bu oranın düşük oluşu modelin yüksek derecede doğrulukla çalıştığını göstermektedir. MAE değeri 0.045 ile modelin tahminlerindeki ortalama hata miktarının oldukça düşük olduğunu ve bu düşük MAE değeri, modelin tahminlerinde yüksek bir kesinlik sergilediğini ortaya koyar. Standart sapma 0.111 ise, modelin tahminlerinin tutarlılığını ve tahminler arasındaki varyansın sınırlı olduğunu yansıtarak, modelin güvenilir ve kararlı çıktılar ürettiğini kanıtlamaktadır.

Dikkate değer olan, F1 skorunun 0.969 olarak hesaplanmasıdır; bu, modelin doğru pozitif tahminlerde ve yanlış negatif tahminlerde sergilediği performansın mükemmel bir uyum içinde olduğunu gösterir. Modelin, karmaşık kentsel dokular içerisinde güvenilir ve hassas konum tespiti sağlama kapasitesinin güçlü bir kanıtıdır.




Şekil 4.7 7. Test uçuşu rotasının gösterimi

Uçuş 8

Şehir alanlarında gerçekleştirilen uçuş test serisinin sekizinci denemesi Şekil 4.8’da gösterilmiştir. Uçuş testi önceki testlerden farklı olarak, belirgin bir şekilde daha yüksek irtifada icra edilmiştir. Bu irtifadaki uçuş, görüntü çözünürlüğü ve çevresel algılama kapasitesi üzerinde belirleyici etkiler yaratmakta ve dolayısıyla navigasyon algoritmasının performansını farklı bir perspektiften değerlendirme fırsatı sunmaktadır.

Otokodlayıcı sinir ağı temelli algoritma, bu artan irtifadan kaynaklanan zorluklara rağmen, toplam 115 nadir görüntü üzerinden gerçekleştirilen konum tespitinde 98 doğru tahmin yaparak %85.2’lik bir doğruluk oranına ulaşmıştır. Bu oran, algoritmanın şehirsal alanların üstünden yüksek irtifada dahi etkili bir şekilde konum tespiti yapabilme kapasitesini göstermektedir.

Ancak, algoritmanın RMSE değeri 0.150 olarak kaydedilmiş, bu da önceki testlere kıyasla daha yüksek bir ortalama kare hata değerine işaret etmektedir. Bu artış, yüksek irtifadan kaynaklanan görüntü detaylarının kaybı gibi faktörlerin algoritmanın tahminlerini zorlaştırdığına ve tahminlerin gerçek değerlerden daha fazla sapma gösterdiğine dair bir gösterge olabilir. Benzer şekilde, MAE değeri 0.054 ile, algoritmanın tahminlerindeki ortalama hata miktarının arttığını göstermekte ve standart sapma değeri 0.140 ile tahminlerin dağılımının genişlediğini belirtmektedir.



Şekil 4.88. Şehir alanı test uçuşunun rotası

F1 skoru 0.891, doğru pozitiflerin yüksek sayısına karşın, yanlış pozitiflerin ve özellikle yanlış negatiflerin varlığı modelin kesinlik ve duyarlılık performansını olumsuz etkilemiştir. Bu sonuçlar, yüksek irtifa uçuşlarının, algoritmanın performansını önemli ölçüde etkileyebileceğini ve bu tür koşullarda modelin doğruluğunu korumak için ek iyileştirmelerin gerekebileceğini ortaya koymaktadır. Özellikle, yüksek irtifa uçuşları sırasında değişen çözünürlük ve perspektif gibi faktörlerin, modelin eğitimi ve optimizasyonu sırasında daha ayrıntılı bir şekilde ele alınması gerektiğini göstermektedir.

Şehirsel Alanlarda İHA Navigasyonu İçin Otokodlayıcı Modelinin Değerlendirilmesi

Çizelge 4.4'te sunulan bulgular, şehirsel navigasyon zorluklarına odaklanan otokodlayıcı modelin performansını ortaya koymaktadır. Şehir ortamlarında karşılaşılan çok sayıda değişken ve potansiyel engelin üstesinden gelmek, İHA teknolojilerinin kentsel araştırma ve operasyonlarda daha geniş bir uygulama yelpazesine sahip olmasını sağlamaktadır. Özellikle, karmaşık coğrafi yapılar ve yoğun yapay yapılarla dolu ortamlara uyum sağlayabilen sistemler, kentsel planlama, acil müdahale ve trafik izleme gibi kritik uygulamalarda değerlidir.

Çizelge 4.4 Şehirsel Alanlarda İHA Navigasyonu İçin Model_4 Otokodlayıcı Modelinin Sonuçları

Güzergâh	RMSE Değeri:	MAE Değeri:	Standart Sapma Değeri:	Doğru Pozitif:	Yanlış Pozitif:	Doğru Negatif:	Yanlış Negatif:	F1 Skoru:
Uçuş 1	0.126	0.057	0.113	138	5	4	0	0.982
Uçuş 2	0.022	0.021	0.004	200	0	0	0	1.000
Uçuş 3	0.068	0.032	0.060	205	2	2	1	0.993
Uçuş 4	0.215	0.095	0.193	149	12	17	3	0.952
Uçuş 5	0.113	0.033	0.108	228	1	7	1	0.996
Uçuş 6	0.016	0.014	0.008	147	0	0	0	1.000
Uçuş 7	0.120	0.046	0.111	157	9	5	1	0.969
Uçuş 8	0.290	0.164	0.239	95	15	2	3	0.913

Geliştirilen otokodlayıcı model, sekiz ayrı uçuş testi boyunca, özellikle ikinci ve altıncı uçuşlarda %100 doğruluk oranı göstererek, yüksek f1 skoru elde etmiştir. Bu, modelin karmaşık şehir dokularını başarıyla işleyebildiğini ve etkili bir navigasyon çözümü sunduğunu göstermektedir.

Bu bulgular, şehirsel navigasyon problemlerine yönelik olarak tasarlanmış otokodlayıcı modellerinin, İHA'nın karmaşık ortamlarda bağımsız hareket kabiliyetini geliştirmede önemli bir rol oynayabileceğini göstermektedir.

Bu çalışmanın bir diğer önemli katkısı, yanlış tahminlerin analizinden elde edilen bulgular aracılığıyla, modelin daha da iyileştirilmesi için yol göstermesidir. Yanlış tahminlerin nedenleri üzerine yapılan derinlemesine incelemeler, modelin hassasiyetini artırmak ve genel performansını yükseltmek için önemli bilgiler sağlamıştır. Örneğin, belirli mimari özelliklerin veya çevresel faktörlerin tahmin hatalarına neden olup olmadığı ve bu etkilerin model tarafından nasıl daha iyi anlaşılıp öğrenilebileceği üzerine odaklanılmıştır.

Sonuç olarak, şehirsel alandaki uçuş testleri, otokodlayıcı tabanlı derin öğrenme modellerinin, İHA'ların kentsel ortamlarda etkili bir şekilde navigasyon yapabilmesi için güçlü ve güvenilir araçlar olduğunu doğrulamıştır. Bu çalışma, gelecekteki araştırmalara, İHA sistemlerinin şehirsel ortamlardaki navigasyon performansını daha da iyileştirmek için katkıda bulunacak değerli içgörüler ve metodolojik bir çerçeve sunmaktadır.

Arazi alanları

Arazi alanları üzerinde gerçekleştirilen İHA uçuş testlerinin analizi, şehirsel ortamlarda yapılan detaylı değerlendirmelerle benzer bir metodolojiyi izler, ancak bazı özgün dinamikler de dikkate alınmıştır. Bu testlerde, İHA'nın uçuş rotası ve algoritmanın tahminleri, şehir alanlarındakine benzer şekilde görselleştirilmiştir. Ancak, arazi koşulları şehirsel ortamlardan farklı olduğundan, bu koşulların algoritmanın performansı üzerindeki etkileri özel olarak incelenmiştir.

Arazi testlerinde, nadir görüntüler kullanılarak, algoritmanın coğrafi özellikleri tanıma ve konum tahmini yapma kabiliyeti değerlendirilmiştir. Performans analizinde, RMSE, MAE, standart sapma ve F1 skoru gibi istatistiksel metrikler hesaplanarak, algoritmanın tahmin doğruluğu ve tutarlılığı ölçülmüştür. Arazi koşullarının getirdiği ek zorluklar, özellikle değişken arazi yapısı algoritmanın adaptasyon yeteneğini sınamış ve bu testler, algoritmanın çeşitli çevresel faktörlere adaptasyonunu gözlemleme fırsatı sunmuştur.

Uçuş 1

Şekil 4.9'de 13 Ekim 2022 tarihinde saat 15:05 ile 15:20 arasında, arazi koşullarında alınan görüntüler üzerinden yapılan konum tahminlerini göstermektedir. Bu uçuş sırasında, toplamda 181 görüntü alınmış ve modelin 140 doğru tahminle önemli bir doğruluk seviyesine ulaştığını göstermektedir. Yanlış tahmin sayısı 41 olarak belirlenmiş olup, bu da modelin genel başarımının değerlendirilmesinde dikkate alınması gereken bir faktördür. Modelin performansını daha iyi anlamak için kullanılan temel metrikler şunlardır.

Çizelge 4.5 1. Arazi Uçuşu Sonuçları

RMSE Değeri:	MAE Değeri:	Standart Sapma	Doğru Pozitif	Yanlış Pozitif:	Doğru Negatif:	Yanlış Negatif:	F1 Skoru:
0.178	0.071	0.235	131	21	20	9	0.897


Bu metrikler, tahminlerin ortalama hatasını ve tahminlerin değişkenliğini göstermektedir. RMSE değeri, modelin tahminlerindeki ortalama karesel hatayı yansıtırken, MAE değeri tüm tahmin hatalarının mutlak ortalamasını temsil eder. RMSE değerinin, aykırı değerlere karşı duyarlılığı nedeniyle yüksek hata değerlerini cezalandırma eğiliminde olduğunu belirtmek önemlidir. Standart sapma ise, tahminler arasındaki değişkenliğin bir ölçüsüdür ve düşük bir standart sapma, modelin farklı örneklerde tutarlı performans gösterdiğini işaret eder.

Arazi alanlarındaki ilk uçuş testinde elde edilen F1 skoru 0.897'dir ve bu, modelin yüksek bir doğruluk seviyesine ulaştığını; ancak şehir alanlarındaki uçuş testlerinde gözlemlenen mükemmel skorlara göre daha düşük bir performans sergilediğini göstermektedir. RMSE değeri 0.178, MAE değeri 0.071 ve standart sapma 0.235 olan model, doğru pozitif tahminlerde (131) iyi bir performans gösterse de yanlış negatif (9) ve yanlış pozitif (21) sonuçlar, modelin arazi koşullarında karşılaştığı

zorlukları ve sınıflandırma dengesindeki bozulmaları ortaya koymaktadır. Bu sonuçlar, modelin arazi gibi değişken doğal çevre şartlarına tam olarak adapte olamadığı ve bu koşullarda şehir alanlarındaki başarı düzeyini yakalayamadığını vurgulamaktadır.

İHA sistemlerinin uygulama bağlamında değerlendirilmesi, modelin gerçek zamanlı karar verme süreçlerindeki performansını ve operasyonel senaryolar arasında genelleştirme yeteneğini kapsamalıdır. Test edilen koşullar altında model yüksek bir doğruluk sergilemiş olmasına rağmen, modelin aşırı uydurma (overfitting) gibi olası sorunlara karşı dirençli olduğunu doğrulamak için çeşitli ortamlarda ek testler yapılması önerilir. Ayrıca, modelin tutarlılık ve güvenilirliğini sağlamak için, farklı coğrafi koşullar ve çeşitli hava durumları gibi parametreler dahilinde testlerin genişletilmesi gerekliliği vardır.

Sonuç olarak, Modelin arazi koşullarında daha düşük performans göstermesi, iki ana faktörden kaynaklanmaktadır: İlk olarak, modelin eğitim verileri büyük ölçüde şehir alanlarından alınmıştır. İkinci olarak, kullanılan SYM verisinin düşük uzamsal çözünürlüğü, modelin arazi üzerinde daha düşük doğrulukta sonuçlar üretmesine yol açmıştır. F1 skoru ve diğer hata metrikleri, modelin genel doğruluk seviyesinin şehir alanlarına göre düşük olduğunu göstermektedir. Ancak, bu sonuçlar modelin farklı senaryolarda ve geniş bir operasyonel yelpazede göstereceği performansı tam olarak yansıtmayabilir. Bu nedenle, modelin sağlamlığını ve güvenilirliğini arttırmak için sürekli iyileştirme ve çeşitli test koşulları altında değerlendirme yapılması önemlidir. Ayrıca, coğrafi veri doğruluğunu arttırmak ve modelin uygulama alanındaki etkinliğini arttırmak için, gerçek değerler ile sürekli karşılaştırmalar yaparak modelin iyileştirilmesi gerekmektedir. Bu yaklaşım, İHA teknolojisinin navigasyon ve konum tespiti konularında gelecekteki uygulamalar için sağlam bir temel oluşturacaktır.



Şekil 4.9 13 Ekim 2022'de arazi koşullarında alınan 181 görüntü için konum tahminleri. Toplamda 140 doğru tahmin ile %77.3 doğruluk oranı gösterilmektedir.

Uçuş 2

Şekil 4.10 'de Belirtilen 2. uçuş 13 Ekim 2022 tarihinde saat 14:41 ile 14:58 saatleri arasında yapılmıştır. Kullanılan yapay zekâ modeli, bir önceki uçuş testinde kullanılan ile aynı model_4 modelidir. Bu modelin performans değerlendirilmesi, algoritmanın genel başarısını ve uygulama alanındaki etkinliğini ölçmek için önemli metrikler ile yapılmıştır.

Elde edilen performans metrikleri şunlardır:

Çizelge 4.6. 2. Arazi Uçuşu Sonuçları

RMSE Değeri:	MAE Değeri:	Standart Sapma	Doğru Pozitif	Yanlış Pozitif:	Doğru Negatif:	Yanlış Negatif:	F1 Skoru:
0.236	0.098	0.272	152	44	28	7	0.856


Model, toplam 211 tahminin 159'unu doğru olarak gerçekleştirmiş, bu da kabaca %75'lik bir başarı oranına işaret etmektedir. RMSE değeri, arazi üzerindeki birinci uçuş testine göre bir miktar yüksektir; bu, tahmin edilen konum değerleri ile gerçek değerler arasındaki ortalama karesel farkın

birinci teste kıyasla daha büyük olduğunu gösterir. Benzer şekilde, MAE değeri de artmıştır ki bu, modelin tutarlılığında ve doğrulukta bir azalma olduğunu düşündürebilir.

Standart sapma, birinci test ile karşılaştırıldığında yine yüksektir, bu da tahminler arasında daha büyük bir değişkenliğin olduğunu göstermektedir. Doğru pozitiflerin sayısında küçük bir artış olmasına rağmen, yanlış pozitif ve yanlış negatif değerlerinde de artış gözlemlenmiştir. Bu, modelin bazı durumlarda fazla iyimser olduğunu ve bazı gerçek negatifleri yanlışlıkla pozitif olarak sınıflandırdığını işaret edebilir.

F1 skoru, birinci testin F1 skoruna göre biraz daha düşüktür (0.897'ye kıyasla 0.856). F1 skoru, modelin doğruluk ve duyarlılığının dengeli bir ölçüsüdür ve bu düşüş, modelin performansının birinci teste göre bir miktar düştüğünü gösterir.

İkinci testin sonuçları, modelin konum tespiti konusunda birinci teste göre bir miktar performans kaybı yaşadığını göstermektedir. Bu durum, modelin farklı güzergahlara ve çevresel koşullara genelleştirme yeteneğini sınama ihtiyacını vurgulamaktadır.



Şekil 4.10. Model 159 doğru, 52 yanlış tahmin yapmıştır. Bu da modelin %79.1 gibi bir başarı yüzdesine sahip olduğunu gösterir.

Uçuş 3

Şekil 4.11 13 Ekim 2022 tarihinde saat 14:41'den 14:58'e kadar yapılan uçuşu göstermektedir. Bu test model_4 otokodlayıcı sinir ağı modeli kullanılarak yapılmıştır. Elde edilen performans metrikleri, modelin konum tespiti kabiliyetinin doğruluğunu ve tutarlılığını değerlendirmek için incelenmiştir.

Metriklerin Değerlendirilmesi

Test sırasında kaydedilen performans metrikleri aşağıdaki gibidir:

Çizelge 4.7. 3. Arazi Uçuşu Sonuçları


RMSE Değeri:	MAE Değeri:	Standart Sapma	Doğru Pozitif	Yanlış Pozitif:	Doğru Negatif:	Yanlış Negatif:	F1 Skoru:
0.130	0.100	0.207	162	10	23	3	0.961

Bu testte, model toplam 198 tahminin 165'ini doğru bir şekilde gerçekleştirmiştir. Bu, modelin genel başarı oranının %83.3 olduğunu göstermektedir. RMSE ve MAE değerleri, modelin tahminlerinin gerçek değerlere ne kadar yakın olduğunu bir göstergesi olarak düşünülebilir ve bu test için diğer testlere nazaran daha düşük hatalar göstermektedir.

Standart sapma değeri, modelin tahminlerinin tutarlılığının bir ölçüsüdür ve bu test için de düşük bir varyans göstermektedir. Doğru pozitif ve yanlış negatif değerleri, modelin pozitif ve negatif sınıfları arasında iyi bir denge kurduğunu ve genel olarak yüksek duyarlılığa ve doğruluğa sahip olduğunu gösterir. F1 skoru 0.961 gibi oldukça yüksek bir değerle, mevcut arazi koşullarında ve uçuş şartlarında modelin performansının güçlü olduğunu gösterir. Bu metrik, modelin doğru konumları bulma konusundaki dengeli yeteneğini ve hem yanlış pozitifleri hem de yanlış negatifleri minimize etme kabiliyetini vurgular.

Üçüncü testin sonuçları, modelin daha yüksek doğrulukta konum tespiti yapabilme kabiliyeti olduğunu göstermektedir. Ancak, bu testin de önceki iki arazi uçuş testiyle birlikte değerlendirilmesi, modelin farklı güzergahlarda ve çeşitli çevresel koşullarda ne kadar etkili çalışabildiğini anlamak için önemlidir.

Otokodlayıcı sinir ağı modelinin genelleştirme kapasitesini artırmak ve daha geniş bir uygulama yelpazesine uyum sağlamasını sağlamak amacıyla, modelin eğitim sürecine daha fazla çeşitlilikte veri eklemek ve sürekli olarak gerçek verilerle karşılaştırarak ayarlamalar yapmak önerilmektedir.



Şekil 4.11 13 Ekim 2022'de arazi koşullarında alınan 198 görüntü için konum tahminleri. Toplamda 165 doğru tahmin ile %83.3 doğruluk oranı gösterilmektedir

Arazi Alanlarında İHA Navigasyonu İçin Otokodlayıcı Modelinin Değerlendirilmesi

Arazi uçuş testleri, otokodlayıcı tabanlı modellerin şehir alanlarına kıyasla arazi koşullarında daha düşük bir başarı sergilediğini ortaya koymaktadır. Çizelge 4.8 'daki analitik değerlendirmeden elde edilen sonuçlar, doğal çevre koşullarının, şehirseller alanlardaki uygulamalara göre, sınır ağı modelleri için ekstra zorluklar oluşturduğunu göstermektedir.

Çizelge 4.8 Arazi Alanları Üzerinde Uçuş Sonuçları

Güzergâh	Model	RMSE Değeri:	MAE Değeri:	Standart sapma Değeri:	Doğru Pozitif:	Yanlış Pozitif:	Doğru Negatif:	Yanlış Negatif:	F1 Skoru:
Ucus_1	Model_4	0.178	0.071	0.235	131	21	20	9	0.897
Ucus_2	Model_4	0.236	0.098	0.272	152	44	28	7	0.856
Ucus_3	Model_4	0.130	0.100	0.207	162	10	23	3	0.961

Örneğin, birinci uçuş için elde edilen 0.897'lik f1 skoru, şehir uçuşlarındaki bazı sonuçlarla karşılaştırıldığında düşüktür. Bu durum, doğal ortamların tahmin performansını negatif yönde etkileyebileceğine işaret etmektedir. Benzer şekilde, üçüncü uçuşta elde edilen 0.961'lik f1 skoru

olumlu olsa da bu oran şehir testlerinde bazı modellerin ulaştığı %100'lük başarı oranlarına ulaşamamaktadır. İkinci uçuş için f1 skoru 0.856'ya düşmekte ve bu düşüş, modelin arazi şartlarında karşılaştığı zorlukların şehirsal alanlardaki performansına göre daha belirgin olduğunu göstermektedir.

Uçuş testleri sırasında elde edilen verilerin analizi, arazi uçuşlarının başarı düzeyinin şehir alanlarındaki uçuşlara kıyasla daha düşük olmasının önemli bir sebebinin, maliyet ve ağırlık gibi unsurlardan ötürü lazer mesafe ölçerler kullanılmadığından, arazi üzerinden yapılan irtifa tahminlerinin doğruluğunu sağlamak için kullanılan Sayısal Yükseklik Modeli (SYM) haritasının nispeten düşük çözünürlüğüne bağlı olabileceğini ortaya koymaktadır. Özellikle, Kapadokya bölgesi gibi topografik yapı itibarıyla değişken özellikler gösteren ve derin vadileri barındıran bir alanda yapılan uçuşlarda, İHA'nın araziye göre irtifasındaki ani değişikliklerin, 30 metre uzamsal çözünürlüğündeki SYM haritasıyla yeterince hassas bir şekilde ölçülememesi, navigasyon doğruluğunu olumsuz etkilemiştir. Bu bulgu, İHA navigasyon sistemlerinin doğal ortamlardaki performansını artırmak için, özellikle değişken arazi koşullarında, daha yüksek çözünürlüklü haritaların entegrasyonunun ve kullanımının gerekliliğine işaret etmektedir.

Bu gözlemler, doğal çevre koşullarının, otokodlayıcı modelin etkinliği üzerinde ciddi bir etkisi olduğunu ve bu koşullarda modelin doğruluğunun şehir alanlarındaki başarı oranlarına kıyasla daha düşük olduğunu ortaya koymaktadır. RMSE ve MAE gibi hata metriklerinin de genel olarak arazi uçuşlarında daha yüksek çıktığı gözlemlenmiş, bu da tahminlerin gerçek değerlerden daha fazla sapma gösterdiğini belirtmektedir.

Sonuç olarak, şehir alanlarında elde edilen yüksek performansın aksine, arazi şartlarında İHA navigasyon sistemlerinin doğruluk oranlarında gözle görülür bir düşüş yaşandığı gözlemlenmektedir. Bu bulgular, İHA navigasyon sistemlerinin doğal ortamlarda karşılaşılabileceği zorlukları üstesinden gelmek ve performansını şehir alanlarındaki seviyelere çıkarmak için ek araştırma ve geliştirmenin gerekliliğini vurgulamaktadır. Bu çalışma, arazi şartlarına uyum sağlayabilen ve yüksek başarı oranlarına ulaşabilen gelişmiş navigasyon sistemlerinin geliştirilmesi için önemli bir referans sunmaktadır.

4.2. Genel Model Performansı ve Değerlendirmeler

Bu çalışma kapsamında, GNSS sinyali alınamayan ortamlarda İHA'ların görsel navigasyon kabiliyetlerini geliştirmek amacıyla, coğrafi koordinat sistemleri ile entegre edilen çapraz otokodlayıcılar kullanılmıştır. Bulgular, bu yaklaşımın İHA'ların karmaşık ortamlarda bağımsız navigasyon yeteneklerini önemli ölçüde geliştirdiğini göstermektedir. Literatürde benzer bir çalışma olan Bianchi ve Barfoot'un çalışması ise, otomatik kodlayıcılar kullanarak uydu görüntülerini sıkıştırarak İHA yer belirleme süreçlerini iyileştirmeyi hedeflemiştir. Fakat, bu çalışma coğrafi koordinat sistemlerinden bağımsız bir metodoloji benimsemiştir ve klasik otokodlayıcılar kullanmıştır. Her iki çalışmanın metodolojik yaklaşımları arasındaki bu temel farklılıklar, İHA

navigasyon sistemlerinde teknolojik yeniliklerin ve metodolojik ilerlemelerin önemini vurgulamaktadır. Özellikle, çapraz otokodlayıcıların kullanımı, İHA'ların navigasyon ve konumlandırma kapasitelerini artırmada önemli bir rol oynayabilir. Bu çalışma, İHA teknolojisindeki potansiyel uygulama alanlarını genişletmekte ve bu alandaki yenilikleri iletmektedir.

Özet olarak elde edilen bulgular, otokodlayıcı tabanlı sistemlerin İHA navigasyonunda, özellikle şehir ve arazi alanlarında, önemli bir potansiyele sahip olduğunu göstermektedir. Şehir alanlarında elde edilen yüksek doğruluk oranları, bu teknolojinin karmaşık çevresel faktörler ve görsel engellerle başa çıkma kapasitesini etkileyici bir şekilde ortaya koymaktadır. Düşük RMSE ve MAE değerleri, modelin tahminlerinin güvenilirliği ve doğruluğu açısından önemli göstergelerdir. Ancak, arazi koşullarında gözlemlenen performans düşüklüğü, modelin farklı çevresel koşullara adaptasyonu ve bu alanlarda geliştirilmesi gereken yönleri işaret etmektedir. Bu çalışma, İHA navigasyon sistemlerinde otokodlayıcılar ve derin öğrenme tekniklerinin kullanımının potansiyelini açıkça göstermekte ve bu teknolojilerin farklı coğrafi yapılar ve çevresel koşullara adaptasyon kabiliyetlerinin artırılmasının, gelecekteki uygulamalarında kritik bir rol oynayacağını vurgulamaktadır. Bu bağlamda, bu araştırma, İHA navigasyon sistemlerinde otokodlayıcı tabanlı yaklaşımların etkin kullanımına dair değerli metodolojik çerçeveleri ve gelecekteki araştırmalara katkıda bulunacak önemli içgörülerini sunmaktadır.



5. SONUÇLAR VE ÖNERİLER

Bu çalışmada, uydu ve Google Haritalar verileriyle eğitilen evrişimli otokodlayıcı sinir ağlarının, insansız hava araçlarının (İHA) görsel navigasyon yeteneklerini nasıl geliştirebileceği araştırılmıştır. Araştırma sonuçları, özellikle GPS sinyallerinin zayıf veya mevcut olmadığı durumlarda, otokodlayıcıların İHA'ların konumlarını daha doğru bir şekilde tespit etmede etkili olduğunu göstermektedir. Bu bulgular, İHA'ların kentsel ve karmaşık coğrafi bölgelerdeki navigasyon yeteneklerini geliştirmede önemli bir adımı temsil etmektedir.

Ancak, çalışmanın sınırlamaları ve veri setinin çeşitliliğinin kısıtlamaları göz önüne alındığında, modelin performansının yapılaşma olmayan ortamlarda farklılık gösterebileceğine dair belirgin işaretler bulunmaktadır. Bu nedenle, daha geniş ve çeşitli veri setleri üzerinde yapılan ileri çalışmalar, bu alanda önemli bir yer tutmaktadır.

Gelecekteki çalışmalar, çeşitli sinir ağı mimarilerinin ve değişken arazi koşullarına özgü veri setlerinin, sinir ağı eğitim stratejileri üzerindeki etkilerini derinlemesine incelemelidir. Özellikle, modelin çeşitli navigasyon senaryolarında ve İHA türlerindeki performansını test etmek ve gerçek dünya ortamlarında uygulanabilirliğini doğrulamak için saha testleri önem taşımaktadır.

Bu çalışma, İHA navigasyon alanında önemli bir katkı sağlamakla kalmayıp hem akademik hem de uygulamalı araştırmalar için yeni yollar açmıştır. Önerilen evrişimli otokodlayıcı sinir ağlarının, İHA teknolojisinin ilerlemesine ve mevcut zorluklara yenilikçi çözümler sunabileceği açıkça görülmektedir.

Bulgular ışığında, gelecekteki çalışmalarda Kalman filtresi ile konum kestirimi yapılması ve farklı uzamsal çözünürlüklerde piramit veri türü ile daha dinamik konum bulma yöntemlerinin denenmesi önerilmektedir. Kalman filtresi, dinamik sistemlerdeki belirsizlikleri azaltmak ve tahmin doğruluğunu artırmak için yaygın olarak kullanılan bir yöntemdir. İHA'ların görsel navigasyon sistemlerinde Kalman filtresinin entegrasyonu, bu sistemlerin doğruluğunu ve güvenilirliğini önemli ölçüde artırabilir. Özellikle, GPS sinyallerinin zayıf veya mevcut olmadığı durumlarda, Kalman filtresi ile entegre edilmiş bir görsel navigasyon sistemi, İHA'ların konumlarını daha doğru ve güvenilir bir şekilde belirlemesine olanak tanıyabilir.

Bunun yanında, farklı uzamsal çözünürlüklerde piramit veri türü ile çalışmak, İHA'ların farklı ölçeklerdeki nesneleri ve arazi özelliklerini daha etkili bir şekilde algılamasını ve işlemesini sağlayabilir. Bu yaklaşım, özellikle karmaşık ve değişken arazi koşullarında, İHA'ların görsel navigasyon kabiliyetlerini geliştirebilir. Piramit veri türü, farklı çözünürlük seviyelerindeki görüntüleri kullanarak, İHA'ların hem geniş alanları kapsayabilmesini hem de detaylı yerel bilgileri işleyebilmesini sağlayabilir.

Sonuç olarak, bu çalışma, İHA navigasyon teknolojilerinin gelişimine önemli bir katkı sunmakta ve bu alanda gelecek araştırmalara yönelik sağlam bir temel oluşturmaktadır. Önerilen

yöntemlerin ve yaklaşımların uygulanması, İHA teknolojisinin sınırlarını daha da genişletecek ve çeşitli uygulama alanlarında etkisini artıracaktır.



KAYNAKLAR

- Ali, B., Sadekov, R. N., & Tsodokova, V. V. (2022). A Review of Navigation Algorithms for Unmanned Aerial Vehicles Based on Computer Vision Systems. *Gyroscopy and Navigation*, 13(4), 241-252. <https://doi.org/10.1134/S2075108722040022>
- Alsallakh, B., Kokhlikyan, N., Miglani, V., Yuan, J., & Reblitz-Richardson, O. (2020). *Mind the Pad—CNNs can Develop Blind Spots* (arXiv:2010.02178). arXiv. <http://arxiv.org/abs/2010.02178>
- Arafat, M. Y., Alam, M. M., & Moh, S. (2023). Vision-Based Navigation Techniques for Unmanned Aerial Vehicles: Review and Challenges. *Drones*, 7(2), 89. <https://doi.org/10.3390/drones7020089>
- Bala, R., & Eschbach, R. (2004). Spatial Color-to-Grayscale Transform Preserving Chrominance Edge Information. *Color and Imaging Conference*, 12(1), 82-86. <https://doi.org/10.2352/CIC.2004.12.1.art00016>
- Bianchi, M., & Barfoot, T. D. (2021). UAV Localization Using Autoencoded Satellite Images. *IEEE Robotics and Automation Letters*, 6(2), 1761-1768. <https://doi.org/10.1109/LRA.2021.3060397>
- Braga, J. R. G., Velho, H. F. C., Conte, G., Doherty, P., & Shiguemori, E. H. (2016). An image matching system for autonomous UAV navigation based on neural network. *2016 14th International Conference on Control, Automation, Robotics and Vision (ICARCV)*, 1-6. <https://doi.org/10.1109/ICARCV.2016.7838775>
- Brunelli, R. (2009). *Template Matching Techniques in Computer Vision: Theory and Practice* (1. bs). Wiley. <https://doi.org/10.1002/9780470744055>
- Cai, Y., Zhang, G., He, Y., Lv, D., Zhang, D., & Luan, X. (2015). *Research on measurable distance extending technology of laser radar* (H. Gong, N. Wu, Y. Ni, W. Chen, & J. Lu, Ed.; s. 967425). <https://doi.org/10.1117/12.2199872>
- Cesetti, A., Frontoni, E., Mancini, A., Ascani, A., Zingaretti, P., & Longhi, S. (2011). A Visual Global Positioning System for Unmanned Aerial Vehicles Used in Photogrammetric Applications. *Journal of Intelligent & Robotic Systems*, 61(1-4), 157-168. <https://doi.org/10.1007/s10846-010-9489-5>
- Ching, W.-S. (1995). Normalized cross-correlation: The contrast-dependent problem and its solution. *Journal of Electronic Imaging*, 4(3), 278. <https://doi.org/10.1117/12.210718>
- Decker, B. L. (1986). *World Geodetic System 1984*, (AD-A167570). Defense Mapping Agency Aerospace Center, Austin, Texas.
- DJI Mavic 2 Product Information*. (2018, Ağustos 3). <https://www.dji.com/mavic-2/info>

- Duo, J., & Zhao, L. (2017). A robust and efficient airborne scene matching algorithm for UAV navigation. *2017 IEEE 9th International Conference on Communication Software and Networks (ICCSN)*, 1337-1342. <https://doi.org/10.1109/ICCSN.2017.8230327>
- ESA-Sentinel Application Platform (SNAP), Copernicus Data. (2023, Ağustos 15). <https://step.esa.int/>
- Farrell, J., & Barth, M. (1999). *The global positioning system and inertial navigation*. McGraw-Hill.
- Fragoso, A. T., Lee, C. T., McCoy, A. S., & Chung, S. J. (2021). A seasonally invariant deep transform for visual terrain-relative navigation. *İçinde Science Robotics* (C. 6, Sayı 55, s. 3320). <https://doi.org/10.1126/scirobotics.abf3320>
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep learning*. The MIT Press.
- Guan, X., & Bai, H. (2012). A GPU accelerated real-time self-contained visual navigation system for UAVs. *2012 IEEE International Conference on Information and Automation, ICIA 2012*, 578-581. <https://doi.org/10.1109/ICInfA.2012.6246879>
- He, L., Nabil, A., & Song, B. (2021). *Explainable Deep Reinforcement Learning for UAV Autonomous Navigation* (arXiv:2009.14551). arXiv. <http://arxiv.org/abs/2009.14551>
- Hou, H., Xu, Q., Lan, C., Lu, W., Zhang, Y., Cui, Z., & Qin, J. (2021). UAV Pose Estimation in GNSS-Denied Environment Assisted by Satellite Imagery Deep Learning Features. *IEEE Access*, 9, 6358-6367. <https://doi.org/10.1109/ACCESS.2020.3048342>
- Howard, R. A. (1970). *Dynamic programming and Markov processes* (6. print). M.I.T. Pr.
- Hu, W., Gharuib, A. M., & Hafez, A. E.-D. S. (2011). Template Match Object Detection for Inertial Navigation Systems. *Positioning*, 02(02), 78-83. <https://doi.org/10.4236/pos.2011.22008>
- Irani, G. B., & Christ, J. P. (1994). Image processing for Tomahawk scene matching. *İçinde Johns Hopkins APL Technical Digest (Applied Physics Laboratory)* (C. 15, Sayı 3, ss. 250-263).
- Jaimes, B. R. A., Ferreira, J. P. K., & Castro, C. L. (2022). Unsupervised Semantic Segmentation of Aerial Images with Application to UAV Localization. *IEEE Geoscience and Remote Sensing Letters*, 19. <https://doi.org/10.1109/LGRS.2021.3113878>
- Jurie, F., & Dhome, M. (2001). A simple and efficient template matching algorithm. *İçinde Proceedings of the IEEE International Conference on Computer Vision* (C. 2, ss. 544-549). <https://doi.org/10.1109/iccv.2001.937673>
- Kerns, A. J., Shepard, D. P., Bhatti, J. A., & Humphreys, T. E. (2014). Unmanned aircraft capture and control via GPS spoofing. *Journal of Field Robotics*, 31(4), 617-636. <https://doi.org/10.1002/rob.21513>
- Khan, S. Z., Mohsin, M., & Iqbal, W. (2021). On GPS spoofing of aerial platforms: A review of threats, challenges, methodologies, and future research directions. *PeerJ Computer Science*, 7, e507. <https://doi.org/10.7717/peerj-cs.507>
- Kim, Y., Jung, W., & Bang, H. (2014). Visual Target Tracking and Relative Navigation for Unmanned Aerial Vehicles in a GPS-Denied Environment. *International Journal of*

- Aeronautical and Space Sciences*, 15(3), 258-266.
<https://doi.org/10.5139/IJASS.2014.15.3.258>
- Kingma, D. P., & Ba, J. (2017). *Adam: A Method for Stochastic Optimization* (arXiv:1412.6980). arXiv. <http://arxiv.org/abs/1412.6980>
- Kinnari, J., Renzulli, R., Verdoja, F., & Kyrki, V. (2023). LSVL: Large-scale season-invariant visual localization for UAVs. *Robotics and Autonomous Systems*, 168, 104497. <https://doi.org/10.1016/j.robot.2023.104497>
- Kwak, J., & Sung, Y. (2019). Autoencoder-based candidate waypoint generation method for autonomous flight of multi-unmanned aerial vehicles. *Advances in Mechanical Engineering*, 11(6), 168781401985677. <https://doi.org/10.1177/1687814019856772>
- LeCun, Y., Bengio, Y., & Hinton, G. E. (1998). *Convolutional Networks for Images, Speech, and Time-Series*.
- Lee, D., Kim, Y., & Bang, H. (2013). Vision-based Terrain Referenced Navigation for Unmanned Aerial Vehicles using Homography Relationship. *Journal of Intelligent & Robotic Systems*, 69(1-4), 489-497. <https://doi.org/10.1007/s10846-012-9750-1>
- 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. <https://doi.org/10.1080/10095020.2017.1420509>
- Meduna, D. K. (2011). *Terrain Relative Navigation for Sensor-Limited Systems With Application To Underwater Vehicles a Dissertation Submitted To the Department of Aeronautics and Astronautics and the Committee on Graduate Studies of Stanford University in Partial Fulfillment O* (Sayı August). <http://purl.stanford.edu/mq108ss0503>
- Meduna, D. K., Rock, S. M., & McEweny, R. (2008). Low-cost terrain relative navigation for long-range AUVs. *İçinde Oceans 2008*. <https://doi.org/10.1109/OCEANS.2008.5152043>
- Mughal, M. H., Khokhar, M. J., & Shahzad, M. (2021). Assisting UAV Localization Via Deep Contextual Image Matching. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 14, 2445-2457. <https://doi.org/10.1109/JSTARS.2021.3054832>
- Oggier, T., Lehmann, M., Kaufmann, R., Schweizer, M., Richter, M., Metzler, P., Lang, G., Lustenberger, F., & Blanc, N. (2004). *An all-solid-state optical range camera for 3D real-time imaging with sub-centimeter depth resolution (SwissRanger)* (L. Mazuray, P. J. Rogers, & R. Wartmann, Ed.; s. 534). <https://doi.org/10.1117/12.513307>
- Parhi, R., & Nowak, R. D. (2020). The Role of Neural Network Activation Functions. *IEEE Signal Processing Letters*, 27, 1779-1783. <https://doi.org/10.1109/LSP.2020.3027517>
- Paris, S., Kornprobst, P., Tumblin, J., & Durand, F. (2007). A gentle introduction to bilateral filtering and its applications. *ACM SIGGRAPH 2007 Courses*, 1. <https://doi.org/10.1145/1281500.1281602>

- Pintelas, E., Livieris, I. E., & Pintelas, P. E. (2021). A convolutional autoencoder topology for classification in high-dimensional noisy image datasets. *Sensors*, 21(22). <https://doi.org/10.3390/s21227731>
- Priddy, K. L., Keller, P. E., & Society of Photo-optical Instrumentation Engineers. (2005). *Artificial neural networks: An introduction*. 165.
- Schmidhuber, J. (2022). *Annotated History of Modern AI and Deep Learning* (arXiv:2212.11279). arXiv. <http://arxiv.org/abs/2212.11279>
- Shakhatreh, H., Sawalmeh, A. H., Al-Fuqaha, A., Dou, Z., Almaita, E., Khalil, I., Othman, N. S., Khreishah, A., & Guizani, M. (2019). Unmanned Aerial Vehicles (UAVs): A Survey on Civil Applications and Key Research Challenges. *IEEE Access*, 7, 48572-48634. <https://doi.org/10.1109/ACCESS.2019.2909530>
- Smith, P. R. (1981). Bilinear interpolation of digital images. *Ultramicroscopy*, 6(1), 201-204. [https://doi.org/10.1016/S0304-3991\(81\)80199-4](https://doi.org/10.1016/S0304-3991(81)80199-4)
- Stefanakis, E. (2017). Web mercator and raster tile maps: Two cornerstones of online map service providers. *GEOMATICA*, 71(2), 100-109. <https://doi.org/10.5623/cig2017-203>
- Strelow, D. W., & Touchberry, A. B. (2012). *NAVIGATION OF UNMANNED AERIAL VEHICLES* (Patent US8315794).
- The European Petroleum Survey*. (2023, Ağustos 10). https://epsg.org/crs_32636/WGS-84-UTM-zone-36N.html
- Valavanis, K. P., & Vachtsevanos, G. J. (Ed.). (2015). *Handbook of unmanned aerial vehicles*. Springer.
- Vincent, P., Larochelle, H., Lajoie, I., Bengio, Y., & Manzagol, P.-A. (2010). Stacked Denoising Autoencoders: Learning Useful Representations in a Deep Network with a Local Denoising Criterion. *Journal of Machine Learning Research*, 11.
- Wang, T., Wang, C., Liang, J., Chen, Y., & Zhang, Y. (2013). Vision-Aided Inertial Navigation for Small Unmanned Aerial Vehicles in GPS-Denied Environments. *International Journal of Advanced Robotic Systems*, 10(6), 276. <https://doi.org/10.5772/56660>
- Warmerdam, F. (2008). The Geospatial Data Abstraction Library. İçinde G. B. Hall & M. G. Leahy (Ed.), *Open Source Approaches in Spatial Data Handling* (C. 2, ss. 87-104). Springer Berlin Heidelberg. https://doi.org/10.1007/978-3-540-74831-1_5
- Wei, P., Liang, R., Michelmores, A., & Kong, Z. (2022). Vision-Based 2D Navigation of Unmanned Aerial Vehicles in Riverine Environments with Imitation Learning. *Journal of Intelligent & Robotic Systems*, 104(3), 47. <https://doi.org/10.1007/s10846-022-01593-5>
- What Is Ground Sampling Distance (GSD) In Photogrammetry?* (2022, Kasım 2). <https://support.skycatch.com/hc/en-us/articles/12586674429843-FAQ-What-is-Ground-Sampling-Distance-GSD-in-Photogrammetry->

- Xu, Y., Wei, Y., Wang, D., Jiang, K., & Deng, H. (2023). Multi-UAV Path Planning in GPS and Communication Denial Environment. *Sensors*, 23(6), 2997. <https://doi.org/10.3390/s23062997>
- Yamamoto, T., Watanabe, J., Nishikawa, Y., & Yawata, K. (2018). UAV vision-based localization techniques using high-altitude images and barometric altimeter. İçinde C. M. Shoemaker, R. E. Karlsen, D. W. Gage, & H. G. Nguyen (Ed.), *Unmanned Systems Technology XX* (s. 21). SPIE. <https://doi.org/10.1117/12.2302401>
- Yang, Y., Lin, Z., & Liu, F. (2016). Stable Imaging and Accuracy Issues of Low-Altitude Unmanned Aerial Vehicle Photogrammetry Systems. *Remote Sensing*, 8(4), 316. <https://doi.org/10.3390/rs8040316>
- Zelinsky, A. (2009). Learning OpenCV---Computer Vision with the OpenCV Library (Bradski, G.R. et al.; 2008)[On the Shelf]. *IEEE Robotics & Automation Magazine*, 16(3), 100-100. <https://doi.org/10.1109/MRA.2009.933612>
- Zhang, Z. (2000). A flexible new technique for camera calibration. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 22(11), 1330-1334. <https://doi.org/10.1109/34.888718>



ÖZGEÇMİŞ

Ahmet Ertuğrul ARIK, Ürgüp, Nevşehir'de yaşamakta ve Osmaniye Korkut Ata Üniversitesi'nde Bilgisayar Teknolojileri Bölümü'nde öğretim üyesi olarak görev yapmaktadır. Eğitim hayatına İstanbul Teknik Üniversitesi'nde Meteoroloji Mühendisliği ile başlamış, ardından Sakarya ve Anadolu Üniversitelerinde Bilgisayar ve Öğretim Teknolojileri Öğretmenliği eğitimi tamamlamıştır. Yüksek lisansını Anadolu Üniversitesi'nde Bilgisayar Mühendisliği alanında yapmış, şu anda ise Çukurova Üniversitesi'nde Uzaktan Algılama ve Coğrafi Bilgi Sistemleri üzerine doktora çalışmalarına devam etmektedir. Kariyerine bilgisayar bilimleri alanında teorik bilgilerini pratikle birleştirerek insanlık için katkı sağlamayı hedefleyen ARIK, özellikle İnsansız Hava Araçları (İHA) ve Derin Öğrenme algoritmaları üzerine çalışmalar yapmaktadır. Akademik kariyeri boyunca birçok projede yer almış, İHA ile 3D modelleme ve sel baskını alanlarının tespiti gibi konularda çalışmalar yürütmüştür. Ayrıca, Osmaniye Korkut Ata Üniversitesi'nin Enformatik Bölümünde öğretim görevlisi olarak görev yapmış, birçok ders vermiş ve çeşitli akademik projelerde yer almıştır.