

## İnsansız Hava Araçlarında Nokta Bulutu Verisi Kullanılarak İniş Pisti Uygunluk Analizi

Ebru KARAKÖSE<sup>1\*</sup>, Melike AKSU<sup>2</sup>

<sup>1,2</sup> Havacılık Elektrik ve Elektronik Bölümü, Sivil Havacılık Yüksekokulu, Fırat Üniversitesi, Elazığ, Türkiye  
<sup>\*1</sup> eozbay@firat.edu.tr, <sup>2</sup> aksumelike23@gmail.com

(Geliş/Received: 24/11/2023;

Kabul/Accepted: 17/04/2024)

**Öz:** İnsansız hava araçları (İHA) açısından gelişen teknoloji ile birlikte kullanım alanları ve üzerlerinde yapılan araştırma çalışmaları her geçen gün artmaktadır. Her ne kadar insansız olarak adlandırılınsalar da İHA'lar bir pilot/uçuş görevlisi yardımıyla kontrol edilmekte ya da otonom uçuşları programlanmaktadır. Yapılan araştırmalar doğrultusunda, yaşanan sorunların ve kazaların büyük bir kısmının İHA'ların inişi sırasında gerçekleştiği belirlenmiştir. Bu oranı azaltacak şekilde iniş aşamasında, iniş pistinin görüntü işleme yöntemleri ile tespit edilmesi ve nokta bulutu sayesinde pistte bulunan engellerin analiz edilmesi bu konuda atılacak önemli bir adımdır. Bu nedenle bu çalışmada, İHA iniş sistemlerinde kullanılabilir ve derin öğrenme ağlarıyla sağlanabilecek uygulamalara yer verilmiştir. Öncelikle, analizi gerçekleştirilecek olan iniş pistinin tasarımı yapılmıştır. Bu pist, çevresinde farklı araç ve engellerin bulunduğu bir ortama bırakılmıştır. Daha sonra, pistin dört rotorlu bir İHA ile farklı yükseklik ve açılardan gerçek görüntüleri ve video kaydı alınmıştır. Alınan görüntüler daha sonra görüntü işleme ve eğitim aşamalarına tabi tutulmak için kullanılmıştır. İHA'nın iniş yapacağı pistin gerçek görüntülerinin alınması, bir veri seti oluşturulması ve alınan bu görüntülerin YOLOv8'de işlenmesi sonucunda İHA iniş pisti tespiti sağlanmıştır. İniş pisti tespitinin ardından pist üzerinde engel bulunma ve bulunmama durumları nokta bulutu verisi kullanılarak incelenmiş ve analizi gerçekleştirilmiştir. Siyah-beyaz ve renkli şekilde verilen derinlik haritaları ile uygulama tamamlanmıştır.

**Anahtar kelimeler:** Görüntü İşleme, İHA İniş Sistemi, Nokta Bulutu, RoboFlow, YOLO.

## Landing Runway Suitability Analysis Using Point Cloud Data in Unmanned Aerial Vehicles

**Abstract:** With the development of technology in terms of unmanned aerial vehicles (UAV), their usage areas and research studies on them are increasing by the time. Although they are called unmanned, UAVs are controlled with the help of a pilot or flight attendant, or their autonomous flights are programmed. In line with the research, it has been determined that most of the problems and accidents occur during the landing of UAVs. In order to reduce this rate, detecting the landing runway with image processing methods and analyzing the obstacles on the runway with the point cloud method during the landing phase is an important step to be taken in this regard. For this reason, this study includes applications that can be used in UAV landing systems and provided with deep learning networks. First of all, the landing runway to be analyzed has been designed. This runway is left in an environment with different vehicles and obstacles around it. Later, real images and video recordings of the runway are taken from different heights and angles with a four-rotor UAV. The captured images have then been used to undergo processing and training stages. UAV landing runway detection has been achieved as a result of taking real images of the runway where the UAV would land, creating a dataset, and processing these images in YOLOv8. After the landing runway has been determined, the presence or absence of obstacles on the runway has been examined and analyzed using the point cloud data. The application has been completed, with depth maps provided in black-and-white and RGB form.

**Key words:** Image Processing, UAV Landing System, Point Cloud, RoboFlow, YOLO.

### 1. Giriş

İnsansız Hava Aracı (İHA), adından da anlaşılacağı gibi içinde yolcu veya pilot bulundurmadan uzaktan kontrol edilen veya otonom şekilde uçuşunu sağlayan bir çeşit hava aracıdır. Kullanıldığı alana, amaca ve göreve göre uygun donanımlar ile (kamera, sensör vb.) donatılarak uçabilme özelliğine sahiptir. Başta askeri ve sivil alanlarda olmak üzere hem ülkemizde hem de tüm dünyada kullanımı hızlı bir şekilde artmaktadır. Kullanım hızının artmasına bağlı olarak üzerinde yapılan bilimsel çalışmalar ve araştırmalar da önemli derecede hız kazanmıştır. Doğru kullanıldığı durumlarda, zaman ve maliyet açısından tasarruf sağlaması amacıyla birçok farklı alanda ve meslek dalında kullanılabilir. İHA'ların sahip oldukları avantajlar ile askeri, sivil ve bilimsel amaçlı profesyonel kullanımlarının sürekli artmasına bağlı olarak önümüzdeki yıllarda da bu araçların daha fazla ilgi odağı olacağı düşünülmektedir. Ayrıca İHA'ların hem ticari hem de spor ya da eğlence amaçlı bu kadar çok

\* Sorumlu yazar: [eozybay@firat.edu.tr](mailto:eozybay@firat.edu.tr). Yazarların ORCID Numarası: <sup>1</sup> 0000-0003-1191-6375, <sup>2</sup> 0000-0002-6695-1592

kullanılıyor olması bu sistemler üzerinde yapılan araştırma ve uygulama çalışmalarının daha detaylı ve hassas bir şekilde yapılması gerekliliğini ortaya koymaktadır [1-7].

Makine öğrenmesi açısından yapay sinir ağları (YSA) birçok sorunun çözümlenmesinde kullanılmaktadır. Ancak bu sistemlerin sahip olduğu kendine has sorunlar ve donanımsal olarak bazı sınırlamalar nedeniyle bu konuda yapılan çalışmalar belirli bir dönem durmuş ardından tekrar ilgi alanı olmaya devam etmiştir. YSA uygulamaları, grafik işlem birimi sistemlerinin gelişmeleriyle birlikte derin ağlara doğru geçiş yapmaya, görüntü işleme, doğal dil işleme ve daha farklı birçok sistemde kullanılmaya başlamışlardır. YSA'ların tarihsel gelişimiyle, derin öğrenme ağlarına geçiş uzun çalışmalar sonucunda gerçekleştirilmiştir. Elde edilen ağlar sayesinde makineler öğrenme özelliği kazandırılarak özerk yani otonom olarak çalışmaları sağlanmıştır. Yapay zekânın başlıkları altında yer alan yaklaşımlardan biri derin öğrenmedir. Derin öğrenme makine öğrenmesi alanı altında son yıllarda oldukça fazla kullanılan yeni bir tekniktir. Ayrıca makinenin verileri çevresinden öğrenmesini ve böylelikle performansını zaman içerisinde geliştirmesi üzerine bir yaklaşımdır. Makine öğrenmesiyle sınıflandırma ve kümeleme işlemleri, gözetimli ve gözetimsiz yöntemleri kullanılarak sağlanmaktadır. Makine öğrenmesinde, insan faktörü kullanılmadan, karmaşık sistemlerin, algoritmaların vb. sistemlerin daha hızlı öğrenilmesini sağlamak için derin öğrenme büyük fayda sağlamaktadır. Literatürde derin öğrenmenin birbirinden farklı birçok tanımı vardır. Temelde, insan beyninde bulunan nöron dediğimiz sinir hücrelerinin birbiriyle iletişiminin yapay bir şekilde taklit edilmesine dayanır. Aslında derin öğrenme insan beyninin karmaşıklığını ve sorun çözme yeteneklerini taklit etmek için kullanılan ve çok büyük miktarda veri kullanan bir makine öğrenmesi türüdür. Sinir ağları ise hiyerarşik olasılık modelleri ve birçok özel denetimli ve denetimsiz özellik öğrenme algoritmaları gibi çeşitli yöntemler içermektedir [8, 9]. Bu alanda yapılan bir çalışmada, derin öğrenmenin tarihi geçmişi, bu alanda geliştirilen yöntemler ve uygulama konularına göre ayrımlarından bahsedilmiştir. Dahası son dönemlerde bu alanda fayda sağlayan alt sistemler ve bu konu üzerine odaklanan çalışmalar hakkında açıklamalara da yer verilmiştir. Çalışmanın hedefi olarak ise bu alanda çalışmak isteyen araştırmacılara derin öğrenme uygulamalarında elde edilen ilerlemeleri anlatmak ve bu sayede çalışılabilir olan konuları vermek olarak açıklanmıştır [10]. Ayrıca literatürde derin öğrenme tabanlı ve özellikle otonom çalışan İHA'lar için farklı amaçlara sahip birçok çalışma ve uygulama gerçekleştirilmiştir [11,12].

Sistemlerin tasarım aşamasında bir model üretimine geçilmeden önce, çalışma sistemini anlamak ve sorunları görmek adına yapılması gereken temel işlemler matematiksel modelinin çıkartılması ve o modelin sayısal olarak test edilmesi uygulamalarıdır. Yapılan modellemeler bazen gerçek sonuçlar ile birebir aynı olmasa da model üzerinde ön fikirler oluşturmaya yardımcı olmaktadır [13-17]. Yapısal olarak farklılıkları ve matematiksel modeli göz önüne alındığında bir İHA için inişin ne kadar riskli ve zor bir aşama olduğu bilinmektedir. Önemli olan bu aşamanın en kolay ve en az kayıpla gerçekleştirilmesidir. İnişini gerçekleştiren İHA'ların bu sırada izlediği adımlar ve kullanılan yöntemler bu konuda mutlak derecede önemlidir. Normal bir iniş, İHA'ya takılan kameralar, sahip olduğu denetleyiciler ve sensörler sayesinde gerçekleştirilmektedir. LIDAR (Laser Imaging Detection and Ranging) teknolojisinin kullanıma geçmesiyle, gelişmesi aynı oranda artmıştır. Bu teknoloji, aynı zamanda nokta bulutu yönteminin gelişmesine de zemin hazırlamıştır. Havadan veya karadan, farklı açılarla yapılan taramalarla elde edilen nokta bulutun oluşturulması için aktif sensörler ve lazer tarayıcılar kullanılmaktadır. Nokta bulutu elde edilmek istenen nesne için ortak bir yaklaşım oluşturularak geometrik girdiler meydana getirilmekte ve milyonlarca nokta nesne üzerinde konumlanarak, nesnenin nokta bulutunun oluşturulması sağlanmaktadır [18-21].

Teknolojinin ve İHA'ların gelişimi sayesinde birçok alanda kullanılan İHA'lardan elde edilen görüntüler üzerinde nokta bulutu verileri kullanılarak haritalar oluşturulabilmiştir. İHA ile bütünleştirilecek olan sensör veya ışık algılayıcı mesafe ölçen (LIDAR) yardımıyla kapalı ve açık ortamlarda bulunan nesnelerin taranması gerçekleştirilerek üç boyutlu bir şekilde nokta bulutu oluşturulmaktadır. Literatür incelendiğinde yapılan bir çalışmada derin öğrenme ağlarıyla üç boyutlu nokta bulutlarının sınıflandırılması üzerine genel bir bakış sunulmuştur. Çalışmada, üç boyutlu nokta bulutunun gelişen teknolojiyle birlikte sınıflandırma, algılama ve tanıma alanlarında kullanıldığı belirtilmiştir. Lazer tarama sistemleri ile nesneler taranarak üç boyutlu nokta bulutuna dönüştürülmüştür. Kullanılan yöntemler ve algoritmalar için başarı durumları, faydalı ve eksik yönleri açıklanarak karşılaştırmalar yapılmış ve analizleri gerçekleştirilmiştir. Ayrıca çalışmada gelecekte bu alanda yapılacak çalışmalara yardımcı olacağı düşünülen bilgilere de yer verilmiştir [22].

Günümüzde halen çeşitli sebeplerden dolayı İHA'lar havadayken veya inerken arızalanıp düşebilmektedir. Bu nedenle, bu arıza ve düşmelerin azaltılması gerekmektedir. Birçok İHA, GPS (Global Position System-Küresel Konumlandırma Sistemi) sinyallerini kullanır ve GPS sinyalleri eksik olduğunda, İHA'lar düzgün bir şekilde inemez. Ancak, optik donanım ve görüntü tanıma teknolojileri yardımıyla, İHA üç boyutlu görüntü elde edilebilir ve bulunduğu ortamı algılayabilir. Gerçekleştirilen [23] numaralı çalışmada, acil durumlarda ve yapılandırılmamış ortamlarda monoküler görüş tabanlı bir İHA otonom iniş sistemi önerilmekte ve uygulanmaktadır. Bu sistemde, görüntüyü gidermek ve farklı yüksekliklerde bir izgara haritası oluşturmak için üç boyut özellikleri ve bir orta geçiş filtresini birleştiren yeni bir harita yaklaşımı önerilmiştir. Ek olarak sonraki iniş alanı seçiminin hızını ve doğruluğunu iyileştirmek amacıyla farklı yükseklikteki izgara alanlarının kenarlarını algılamak için bir bölge

segmentasyonu sunulmuştur. Bu çalışmada önerilen algoritmanın iki amaçla kullanıldığı belirtilmiştir. Bunlar, iniş alanının yeniden yapılandırma bütünlüğü sağlamak ve iniş yeri güvenliği olarak belirlenmiştir. Bu amaçlarla, öncelikle İHA iniş alanını taramış ve monoküler görsel eş zamanlı yerleştirme ve haritalama sistemindeki anahtar kareleri elde etmiştir. Ortamı tahmin ettikten sonra ise üç boyutlu bir nokta bulutu haritası oluşturulmuştur. Daha sonra filtrelenmiş üç boyutlu nokta bulutu haritası ızgara haritasına dönüştürülmüştür. Izgara haritası, uygun iniş bölgesini seçmek için farklı bölgelere ayrılmıştır. Böylece otonom rota planlaması yapılabilmektedir. Son olarak ise çalışma farklı alanlarda deneyerek yapılabilirliği kontrol edilmiştir.

Üç boyutlu bina modellemesi, doğal afetlerin izlenmesi, kentsel kullanım alanlarının belirlenmesi, haritalandırma, hava kalitesinin ölçülmesi gibi çalışmalarda uzaktan algılama kullanılmaktadır. Uzaktan algılamayla alınan görüntülerin işlenmesi gerekmektedir. Alınan görüntüler nokta bulutları haline getirilerek işlenebilmektedir. Görüntü işleme yapılırken lazer tarayıcıdan alınan görüntülerin veya ölçüm sonuçlarından elde edilen nokta bulutları düzensiz bir yapıya sahiptir. Büyük oranda ve düzensiz halde gelen işlenmemiş üç boyutlu nokta bulutu verilerinin işlenerek anlamlı hale gelmesi için bilgisayarlı görü yöntemi kullanılmaktadır. Bilgisayarla görü uygulamalarında evrimsel sinir ağlarının (Convolutional Neural Networks-CNN) kullanılmaya başlanması ve hem yazılımsal hem de donanımsal gelişmeler sayesinde bu alanda yapılan çalışmalar daha da artmıştır [24-26]. Bu konuda yapılan [27] numaralı çalışmada bilgisayarla görü alanında genel bilgilere yer verilerek bu alanda yapılan uygulamalardan ve bu tür sistemlerde probleme sebep olan etmenlerden bahsedilmiştir. Gerçekleştirilen [28] numaralı çalışmada ise okyanuslarda çevresel algılama amacıyla otonom hareket eden bir deniz aracının iniş pistini takip etmek ve inmek için otonom çalışan bir quadrotorun kontrol algoritması geliştirilmiştir. Algoritma, okyanuslarda rüzgârlar ve akıntılar nedeniyle yaygın olan (hedefin sallanmasına ve sürüklenmesine neden olan) zorlu iniş koşullarının zorluğunu üstlenmiştir. Quadrotor için geliştirilen ve iniş pisti algılama, MATLAB kullanılarak görüntü işleme teknikleriyle sağlanmıştır. Testlerin hem iç mekânlarda hem de dış mekânlarda ve açık su üzerinde büyük bir başarı oranı ile gerçekleştirildiği belirtilmiştir. Quadrotor için oluşturulan bu otonom kontrol algoritmasının, çalışma bölgesini geliştirdiği, baz istasyonuna geri uçuşa ihtiyacı olmadığını ve böylece uzak okyanus konumlandırma alanlarında uçuş süresinden tasarruf sağladığı söylenmiştir. Yine bu amaçlara uygun olarak tasarlanmış ve İHA'larda inişi konumlandırma amacıyla gerçekleştirilen farklı çalışmalar da bulunmaktadır [29, 30].

Bu çalışmada, görevini tamamlayıp inişe hazırlanan bir İHA'nın iniş pisti uygunluk analizinin nokta bulutu verisi sayesinde gerçekleştirilmesine dair bilgilere yer verilmiştir. Bu bilgiler doğrultusunda öncelikle İHA'larda inişin gerçekleşmesi ve iniş fazları konusu araştırılmıştır. Daha sonra derin öğrenme mimarileri ve derin öğrenme uygulamalarından bahsedilmiştir. Uygulama kısmında gerçek bir dört rotorlu İHA (quadrotor) tarafından alınan farklı görüntüler için RoboFlow ve YOLOv8 uygulamalarından elde edilen bulgular değerlendirilmiş ve iniş pisti tespiti yapılmıştır. Tespiti yapılan pistin iniş için uygunluk analizi nokta bulutu kullanılarak gerçekleştirilmiştir. Son bölümde ise çalışmanın sonuçları, başarı durumu ve geliştirilebilirliği üzerine gerekli bilgilere yer verilmiştir.

## 1.1. Problemin Tanımı

Uçuşun tüm aşamaları ele alındığında yüksek fiziksel kısıtlamaları nedeniyle en zorlu görev iniş aşamasında gerçekleşmekte ve kazaların büyük bir çoğunluğu da iniş aşamasında meydana gelmektedir. Bu nedenle, pilotlar inişlerine yardımcı olması için ILS (Instrument Landing System-Aletli İniş Sistemi) kullanılmaktadır. ILS pist başlarına yerleştirilmiş vericiler sayesinde inişe yardımcı olan bir yaklaşma sistemidir. Bu sistem, normal uçakların inişi için kullanıldığı gibi aynı zamanda İHA'lar içinde pilot yardımcı inişlerde kullanılmakta ve hem dikey hem de yatay düzlemde İHA'ların yönlendirilmesi için yol göstermektedir. İstatistiksel olarak ILS ve diğer yardımcı sistemler pilotların iş yükünü önemli ölçüde azaltmaktadır. Ayrıca pilotlar uçuş belirsizlikleri, olumsuz hava koşulları ve sistem arızası gibi istenmeyen durumları dikkate almak üzere eğitilirler. Pilot kontrolündeki İHA'larda inişin başarılı bir şekilde gerçekleşmesi için yerleşik sensörlerin kesinliği, aktuatörlerin performansı ve pilot becerileri önemli rol oynamaktadır. Bilindiği gibi İHA'ların iniş sürecindeki en büyük zorluklardan birisi iniş hedeflerinin belirlenmesidir. Çevre ve uçuş güzergâhı bilgilerinde ise görsel ölçümlerin doğruluğunun yüksek olması gerektiği bilinmektedir. INS (Inertial Navigation System-Atalet Seyrüsefer Sistemi) anında konumlandırma bilgisi sağlar ancak uzun süreli konumlandırma doğruluğunu garanti edemez. GPS ise açık alanlarda kullanılabilir, ancak bir miktarda olsa konumlandırma hatalarına neden olabilir ve binalar tarafından sinyalleri bloke edilebilir. Pilot kontrollü bir İHA'da insan etkisi büyük olacağından hata oranı yüksek, karar verme seviyesi düşük ve ek olarak da personele yorucu bir iş düşmektedir. İniş manevraları gibi karmaşık olaylarda da hata yapma istatistikleri oldukça fazladır. Bu durumlar araştırmacıları otomatik iniş sistemlerini veya inişi kolaylaştıracak sistemleri incelemeye yöneltmiştir. İHA'ların güvenli bir iniş gerçekleştirebilmesi için yüksek hassasiyetli konumlandırma sistemleri ve diğer sistemlerden doğru bilgiler alması gerekmektedir. Konum ve yönelim bilgileri için sıradan GPS ve IMU (Inertial Measurement Unit-Atalatsel Ölçüm Birimi) kullanılır. Çevre ve uçuş yolu bilgileri görsel


ölçümler (yerleşik bir kamera gibi) sayesinde doğrulanır. Ayrıca farklı uygulamalardan alınan dijital görüntüler sayesinde yüksek boyutlu verilerin çıkarılmasında da büyük bir ilerleme görülmektedir [31, 32].

İHA'lar için kaza oranlarının büyük çoğunluğu genellikle iniş aşamasında gerçekleşmektedir. Bu nedenle, bu çalışmada iniş anındaki hataları ve kazaları en az seviyeye indirgenebilmesi amacıyla araştırmalar gerçekleştirilmiştir. Bu amaç doğrultusunda iniş anında iniş pisti üzerinde bulunan engellerin nokta bulutu verisi sayesinde analiz edilmesi sağlanmıştır. İHA'nın uçuşu anında, inişe hazırlanırken ve pist üzerinden uçarken pist görüntülerinin alınması ve alınan görüntülerin işlenerek nokta bulutu yardımıyla pist üzerindeki engellerin analiz edilmesi gerçekleştirilmiştir. Çalışma doğrultusunda pistin farklı açılardan ve yüksekliklerden alınan gerçek görüntülerinin, YOLOv8 kullanılarak çok hızlı bir şekilde görüntü kalitesi artırılmış ve görüntü işleme yapılmıştır. Pist görüntülerinin işlenmesi ve tespit edilmesi sonucunda pistin üzerinde bulunan engeller derinlik analizi yapılarak incelenmiştir. Ek olarak, İHA'lar kullanılarak alınan görüntülerden ve videolardan derin öğrenme temelli nesne tespiti yapılması üzerine literatürde birçok çalışma bulunmaktadır [33-35]. Ancak bahsi geçen çalışmalar genellikle sadece hedeflenen nesnelerin tespiti üzerine odaklanmıştır. Bu çalışmada gerçekleştirilen uygulamada ise İHA ile alınan gerçek görüntülerden nesne tespiti ve iniş pisti tespiti yapıldıktan sonra asıl amaç pist üzerinde engel varlığının nokta bulutu yardımı ile analiz edilmesi olarak tanımlanmıştır. Bu bakımdan bu çalışma, farklı ve özgün bir öneri sunmaktadır. Ayrıca, İHA'lardan alınan görüntülerden nokta bulutu yardımı ile önemli binaların üç boyutlu modellerinin oluşturulduğu, haritalama yapıldığı ve bu haritalardan yol planlama uygulamalarının yapıldığı çalışmalar da bulunmaktadır [36, 37]. Ancak nokta bulutu ile iniş pistinin analiz edilerek engel bulunma durumuna bağlı bir şekilde inişe uygunluğunun değerlendirilmesi temelli bu çalışma literatür açısından farklılık oluşturmaktadır.

## 2. Materyal ve Yöntem

İHA'lar için uçuş operasyonu esnasında en önemli aşama iniş aşamasıdır. İniş anında pistin uygunluğu, pistte herhangi bir engelin olup olmadığı iniş için önemli bir unsurdur. Bu çalışmada, iniş pisti nokta bulutu verisi sayesinde taranarak ve pist üzerinde bulunan engeller pistin derinliği algılanarak kolaylıkla ayırt edilmiştir. Nokta bulutu üç koordinat düzleminde de sayısal olarak binlerce noktadan oluşan, nesnenin dış yüzeyini temsil etmek için kullanılan üç boyutlu bir dijital çıktıdır. Nokta bulutuyla oluşturulan üç boyutlu veriler kalite kontrol, animasyon gibi alanlarda kullanıldığı gibi derin öğrenme yöntemleriyle birlikte kullanılarak görüntü işleme, şehir planlaması ve birçok alanda da kullanılmaktadır [38-40]. Nokta bulutları günümüzde değişik yöntemlerle elde edilebilmektedir. Havadan lazer tarama (Airborne Laser Scanning-ALS), hava araçları yardımıyla belirli bir irtifadan yeryüzünün taranmasıyla gerçekleştirilen bir yöntemdir. Bu yöntemde hızlı bir tarama gerçekleşmiş olur fakat görüş alanı kısıtlıdır. Yeryüzünde sabit noktalarda bulunan araçlarla yapılan lazer tarama (Terrestrial Laser Scanning -TLS) ise kullanılan ikinci bir yöntemdir. Bu yöntemin en büyük avantajı alanın istenilen açılarla daha yüksek ve doğru örnekler ile taranmasıdır. Dezavantajı ise tarayıcının alana yakın olması dar bir görüş alanı sağlarken ayrıca yüksek yoğunluklu tarama sonucu nokta bulutun işlenmesinin zorlaşmasıdır. ALS ve TLS haricinde kullanılan diğer bir yöntem ise taşınabilir mobil lazer taramadır. Bu yöntem taşıma kolaylığı ve hareket halindeyken de veri elde edilme imkanı sağlamaktadır. Bu yöntem iç ve dış mekânlarda kullanılan bir yöntemdir [41-43]. Tüm bu lazer kullanılan yöntemler haricinde ayrıca verilen fotoğrafın nokta bulutu haline getirildiği uygulamalar da bulunmaktadır.


Bu çalışmada, görüntü işleme ve nokta bulutu ile iniş pisti analizi yapabilmek amacıyla öncelikle bir quadrotor ile inişin gerçekleştirilmesi için tasarlanan pistin havadan gerçek görüntüleri alınmıştır. Alınan görüntülerden RoboFlow uygulamasında veri seti oluşturularak YOLOv8'de görüntü işleme için kullanılmıştır. İşleme sonucunda tespiti yapılan iniş pistinin üzerinde engel olup olmama durumuna göre nokta bulutu yardımıyla derinlik ölçülerek iniş pistinin inişe uygunluğu analiz edilmiştir. Çalışma yöntem aşamaları Şekil 1'de gösterilen akış şemasında verilmiştir.



Şekil 1. Çalışma akış şeması.


## 2.1. İniş Pistinin Tasarlanması ve Görüntülenmesi

Uçuşunu gerçekleştiren İHA'nın iniş sırasında zarar görmemesi için öncelikle bir iniş pisti tasarlanmıştır. Bu çalışmada, İHA'nın kolaylıkla görebileceği ve üzerine iniş sağlayacağı Şekil 2'de verilen iniş pisti oluşturulmuştur. Pist 50x70 cm boyutlarına ve doğada çok fazla bulunmayan turuncu rengine sahiptir. Ayrıca pist üzerinde uzaktan kolaylıkla algılanabilecek H harfi bulunmaktadır.




Şekil 2. Tasarlanan iniş pisti.

Pist görüntüsünün işlenebilmesi ve veri setinin oluşturulabilmesi için gerçek bir quadrotor ile farklı yükseklik ve farklı açılardan işlenecek gerçek pist görüntüleri ve video kaydı alınmıştır. Pist görüntüleri alınırken ayrıca pist üzerinde engel bulunacak şekilde de görüntüleme yapılmıştır. Üzerinde engel bulunmayan ve bulunan pist görüntüleri nokta bulutu ile derinlik ölçülüp analiz yapılırken kullanılmıştır. Şekil 3'te farklı yüksekliklerden alınmış engelsiz ve engelli pist görüntüleri verilmiştir.



(a) Engelsiz pist görüntüleri.



(b) Engelli pist görüntüleri.

Şekil 3. Farklı yükseklik ve açılardan alınmış engelsiz ve engelli pist görüntüleri.

## 2.2. RoboFlow ile Veri Seti Oluşturulması

Bu çalışma kapsamında, pist üzerinden alınan video kaydından çıkarılan gerçek görüntüler ayrıştırılarak, YOLOv8'de işlenmek için öncelikle RoboFlow sayesinde veri seti oluşturulmuştur. RoboFlow, nesne algılama ve segmentasyon işlemleri için kullanılan yapay zeka algoritmalarının açık kaynaklı bir kitaplığıdır. Veri seti oluşturulurken elde edilen görüntülerde bulunan cisimler işaretlenerek YOLOv8'de gerçekleştirilecek öğrenmenin kolaylaştırılması sağlanmıştır.

Makine öğrenmesi uygulamalarında elde edilen veri setlerinin modellerde kullanılabilir hale getirilebilmeleri için bölme işlemine tabi tutulmaktadır. Böylece modellerin daha başarılı bir şekilde gerçek dünya ile uyumlu olması hedeflenmektedir. Bölme işlemi uygulama türüne ve göreve bağlı olarak değişmekle birlikte burada,

RoboFlow ile etiketlenen görseller YOLOv8’de eğitilebilmek için test, doğrulama ve eğitim veri setleri olarak bölünmüştür. Bu sayede, test veri seti üzerinde tahminler ve değerlendirmeler yapılırken, doğrulama veri setinde iyileştirmeler yapılmakta ve eğitim veri seti öğrenme amacı ile kullanılmaktadır. Bu çalışmada, öğrenme için yaklaşık 3528 görüntü kullanılarak, veri seti içerisinde iniş pisti, araba, uçak ve ağaç nesnelерinin işaretlenmesi sağlanmıştır. Kullanılan 3528 görüntüden 354’ü test, 705’i doğrulama (validation) ve geriye kalan 2469 görüntü ise eğitim (train) için kullanılmıştır. Şekil 4’te görüldüğü gibi, 3528 görüntünün hepsi için içeriğinde bulunan nesnelер işaretlenmiştir. İşaretleme esnasında iniş pisti; pembe, ağaçlar; yeşil, araba; mor ve uçak; kırmızı renkle gösterilmiştir.



Şekil 4. RoboFlow üzerinde veri seti oluşturulması.

### 2.3. YOLOv8 ile Nesne Tespiti

YOLO nesne tespiti, nesne sınıflandırma, segmentasyon ve poz tahmininde kullanılan bir algoritmadır. Bu algoritmanın temel çalışma yapısı konvolüsyonel sinir ağlarıdır. “You Only Look Once” açılımının baş harflerinden ismini almaktadır. Bu açılım “Yalnızca Bir Kez Bak” anlamına gelmektedir. Nesne tespitinde kullanılan daha iyi tahmin yapan algoritmalar bulunmaktadır fakat YOLO’yu diğer algoritmalarından ayıran en temel fark hızıdır. YOLO’nun bu kadar hızlı olmasının temel sebebi diğer algoritmalar nesne tespiti yaparken ayrı ayrı CNN sınıflandırıcısı kullanarak işlem sayısını arttırmış ve buna bağlı olarak düşük FPS değerine (Frames per second) yani saniyede alınan kare miktarına sebep olur. YOLO ise nesne tespitini tek bir regresyon problemi olarak ele almaktadır. İşlemi gerçekleştirmek için öncelikle girilen resim karesini NxN boyutunda ızgaralara bölmektedir, ızgara boyutları 4x4, 5x5, 8x8 vs. boyutlarında olabilmektedir. Her ızgara kendi alanında nesne olup olmadığını öncelikle tespit eder daha sonra eğer nesne varsa orta noktasında olup olmadığını tespitini yapar. Eğer nesne ızgaranın orta noktasındaysa, nesnenin uzunluğunu, yüksekliğini ve sınıfının tespitini yapar. YOLO her ızgarada ayrı ayrı tahmin vektörü oluşturmaktadır ve bu tahmin vektörlerinin içinde ızgara içinde nesne olup olmadığından emin olan ve nesne varsa 1 yoksa 0 değerini alan güven skoru bulunur. Ayrıca nesnenin orta noktasının x koordinatını veren Bx, nesnenin orta noktasının y koordinatını veren By, nesne genişliğini veren Bw, nesne yüksekliğini veren Bh değerleri bulunmaktadır. YOLO, YOLOv2, YOLOv3, YOLOv4, YOLOv5, YOLOv6, YOLOv7 ve YOLOv8 olmak üzere farklı çeşitlere sahiptir. YOLO’nun son zamanlarda en çok kullanılan ve bu çalışmada tercih edilen çeşidi YOLOv8’dir. Bunun sebebi ise gerçek zamanlı nesne tespiti yaparken diğer çeşitlerine göre daha hızlı olmasıdır. Ayrıca YOLOv8 diğer YOLO çeşitlerine göre hız ve doğruluk açısından çok iyi sonuçlar vermektedir. Makine öğrenmesi modellerinde modelleri değerlendirmek için farklı parametreler bulunmaktadır. Kesinlik (precision) pozitif durumun doğru sınıflandırmasını ölçerken, duyarlılık (recall) parametresi gerçek pozitiflerin ne kadar pozitif olduğunu göstermektedir. F1-skor ise kesinlik ve duyarlılık parametrelerinin harmonik ortalamasını gösteren ve uç durumların da dikkate alındığı bir metriktir. mAP parametresi ise ortalama duyarlılık değerini göstermektedir. Bu metriklerden bir diğeri ise model performans değerlendirmeleri için sıklıkla kullanılan karmaşıklık (karışıklık, karışıklık) matrisidir (confusion matrix). Karmaşıklık matrisi, sınıflandırma problemlerinde modellerin başarı durumunu gösteren bir tablodur ve aslında NxN boyutunda bir matristir. Bu matris çok sınıflı problemler açısından oldukça uygun olmakta ve modelin

doğruluğu hakkında bilgiler vermektedir. Karmaşıklık matrisi için köşegen üzerindeki değerlerin yüksek olması model performansı açısından olumlu bir durumdur. Çünkü bunlar modelin doğru tahmin ettiği etiketlerdir. Bu köşegen değerleri dışında kalan değerler ise hata değerleridir. YSA’larda eğitim aşamasında tahmin hatası kayıp (loss) olarak adlandırılır ve önemli bir etmendir. Ağın gradyanlarını hesaplamak amacıyla kayıp fonksiyonları kullanılmakta ve ağırlıklar güncellenmektedir. Başka bir ifade ile kayıp fonksiyonları tahmin değerinin gerçek değerden ne kadar uzak olduğunu ölçmekte yani gerçek ve olası değer arasındaki kaybı göstermektedir [44-46]. Bu çalışmada, iniş pisti tespiti ve analizini yapmak için YOLOv8’de iniş pistine ait havadan çekilmiş fotoğraf kareleri işlenmiştir. YOLOv8 kendisine verilen görüntü karelerini NxN ızgaralara bölmüş ve nesnelerin çevresini renkli sınırlayıcı kutu (bounding box) ile çevrelemiştir. Daha sonra YOLOv8 ile nesne tespiti yapılmış tüm parametreler açısından elde edilen grafikler ve karmaşıklık matrisi bulgular bölümünde verilmiştir.

## 2.4. Nokta Bulutu ile İniş Pisti Analizi

Çalışma kapsamında, PyCharm ortamında Python dili kullanılarak verilen pist görüntülerinin nokta bulutu analizi yapılmıştır. İHA uçuş yaparken, aynı yükseklikten pistin; sağdan, soldan önden ve arkadan gerçek görüntüleri alınmıştır ve alınan bu görüntüler daha sonra nokta bulutu ile derinlik hesaplaması yapmak için kullanılmıştır. Yapılan derinlik hesaplamalarına bağlı olarak pist üzerinde engel olup olmadığı hakkında fikir sahibi olunabilmektedir. Pist üzerindeki engel tespit edilmesi durumunda İHA’nın inişini gerçekleştirip gerçekleştirmeyeceğine karar verilebilir. İniş pistinin derinlik analizinin yapılabilmesi için görüntülerin bazı işlemlerden geçmesi gerekmektedir. İşlem basamakları Şekil 5’te verildiği gibidir.



Şekil 5. Görüntü işleme basamakları.

### **Görüntünün alınması**

Öncelikle nokta bulutu yardımıyla işlenmek istenen görüntüler, İHA kamerası ile aynı yükseklikten olacak şekilde pistin sağ, sol, ön ve arka kısmından alınır.

### **Renkli görüntünün gri forma dönüştürülmesi**

Alınan renkli yani RGB ( Red: Kırmızı, Green: Yeşil, Blue: Mavi) formda bulunan görüntü gri forma dönüştürülür. Bu işlemin temel amacı görüntünün sahip olduğu üç kanallı RGB formunun tek kanallı gri forma dönüştürülmesi ve görüntü boyutunun küçültülmesidir. Bu sayede algoritma hızı arttırılmış olur. Gri tonlu görüntüde 256 adet gri değeri bulunur. 0 gri değeri siyahı temsil ederken 255 gri değeri ise beyaza karşılık gelmektedir ve gri tonları bu değerler arasında koyudan açığa doğru değişir.

### **Görüntünün eşiklenmesi**

Eşikleme nesnelerin arka plandan ayrılması işlemidir. Bu sayede görüntü üzerindeki gürültü ve parazitler azalarak nesne daha belirgin bir hale gelmiş olur.

### **Görüntünün filtrelenmesi**

Genellikle görüntüdeki gürültü veya parazitlerin ortadan kaldırılması için yapılmaktadır. Bu işlem sonucunda görüntüden ışık yoğunluğuna veya diğer etkenlere bağlı olarak ortaya çıkan parazitler kaldırılarak fotoğraf yumuşatılır [47-51].


## 3. Bulgular ve Tartışma

### 3.1. YOLOv8 ile Nesne Tespiti için Elde Edilen Bulgular

Gerçek bir İHA yardımı ile alınan görüntülerden nesne tespitinin yapıldığı ve nokta bulutu ile iniş pistinin analizinin gerçekleştirildiği bu çalışmada, Şekil 6, YOLOv8’den elde edilmiş pist, uçak, araba ve ağaç görüntülerinin işlenmiş ve sınırlayıcı kutu ile işaretlenmiş hallerini göstermektedir. İşaretlemelede, 0 numaralı sınırlayıcı kutu ağacı, 1 numaralı sınırlayıcı kutu arabayı, 2 numaralı sınırlayıcı kutu iniş pistini ve 3 numaralı sınırlayıcı kutu ise uçağı göstermektedir. Farklı uzaklıktan ve farklı açılardan alınmış gerçek görüntülerin hepsinde iniş pisti, ağaç, araba ve uçak nesnelerinin tespiti gerçekleştirilmiştir. Ayrıca üzerinde engel bulunan pist görüntülerinin tespiti de kolaylıkla yapılmıştır. Şekil 7’de sınıflandırma açısından etiketlenen her sınıf için kaç görüntü bulunduğu verilmiştir. En çok etiketlenme yapılan sınıfın iniş pisti olduğu şekilden açıkça görülmektedir.



Şekil 6. YOLOv8 ile elde edilen işlenmiş görüntü örnekleri.




Şekil 7. Tüm sınıflar için etiketlenen görüntü sayısı.


YOLOv8 modelinde işlenen görüntülerden tespit edilmek istenen pist, ağaç, araba ve uçak verilerinin ne kadar doğru tespit edildiği karmaşıklık matrisinde verilmiştir. Bu matris ile veri setinde etiketlenen sınıf ile eğitilen model tarafından tahmin edilen sınıf arasındaki uyum gösterilmektedir. Şekil 8'de verilen karmaşıklık matrisinde işlenmesi için kullanılan görüntülerin doğru ya da yanlış tahminlerinin sayısı tabloda yüzde olarak verilmiş ve bu tabloya bakılarak modelin performansı yorumlanabilmektedir. Algoritmaya verilen ağaçların %66'sının, arabaların neredeyse tamamına yakını olan %99'unun, iniş pistinin %97'sinin ve verilen uçak görüntü karelerinin %100'ünün doğru bir şekilde algılandığı orta kısımdaki kutucuklarda verilmiştir. Alt kısımda verilen kutucuklarda ise görüntülerin algılanamayan yani algoritmanın hata verileri görülmüştür. Bu verilere göre ise verilen ağaç görüntülerinin %34'ünde, arabanın %1'inde ve iniş pistinin %3'ünde hata oluşmuştur. Çizelgenin sağ tarafında verilen renk çizelgesinde ise verilerin oranına göre hangi renkte olacağı tanımlanmıştır. Çizelgenin üst kısmına doğru ilerledikçe renk beyazdan koyu maviye doğru ilerlemekte ve renk koyulaştıkça verinin miktarı artmaktadır.




Modelin değerlendirilebilmesi açısından önemli parametrelerden birisi olan kesinlik (precision) değişkeninin grafiği Şekil 9’da verilmiştir. Şekil incelendiğinde sağa ve üste doğru gittikçe modelin doğruluk oranı artmaktadır. Bu durum yapılan tahminlerin doğruluğunu göstermektedir. Şekillerde koyu-kalın mavi çizgi ile belirtilen değer, tahmin edilen tüm sınıfların ortalamasını vermektedir.



Şekil 8. Karmaşıklık matrisi.



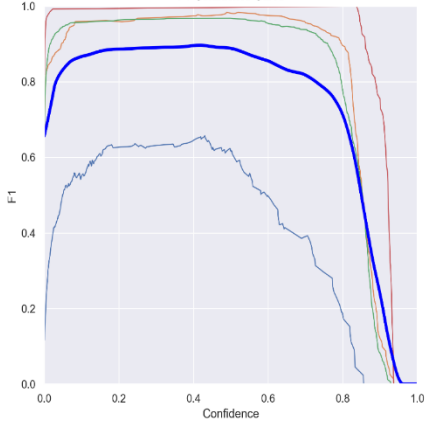
Şekil 9. Kesinlik (Precision) parametresinin değişim grafiği.




Şekil 10. Duyarlılık (Recall) parametresinin değişim grafiği.

YOLOv8’de oluşturulan modelin duyarlılık (recall) parametresi açısından değişim grafiği Şekil 10’da verilmiştir ve şekilden anlaşıldığı gibi model istenen şekilde çalışarak görevini başarılı olarak yerine getirmiştir. Ayrıca tüm tahminlerin ortalamasını gösteren koyu ve kalın mavi çizginin 0,99 değerine ulaştığı görülmüştür. Bu değer model için oldukça yüksek bir başarı oranıdır. Model performansı açısından en önemli parametrelerden birisi olan ve kesinlik ile duyarlılık parametrelerinin harmonik ortalamasını kullanan F1-skor metriği için değişim grafiği ise Şekil 11’de verilmiştir. Modelin tahmini doğruluk oranını gösteren bu eğri için yine başarılı bir sonuca ulaşıldığı görülmüştür. Bu çalışmada, YOLOv8’de nesne tespiti için oluşturulan model performansı

incelendiğinde; bütün parametreler açısından modelin tüm sınıfları ve bu çalışma açısından önem arz eden iniş pistini doğru bir şekilde tespit ettiği görülmüştür. Ayrıca Şekil 12’de verilen kesinlik-duyarlılık grafiğinde %91,4’lük bir mAP değeri ile modelin başarısı ve güvenilirliği ortaya koyulmuştur.

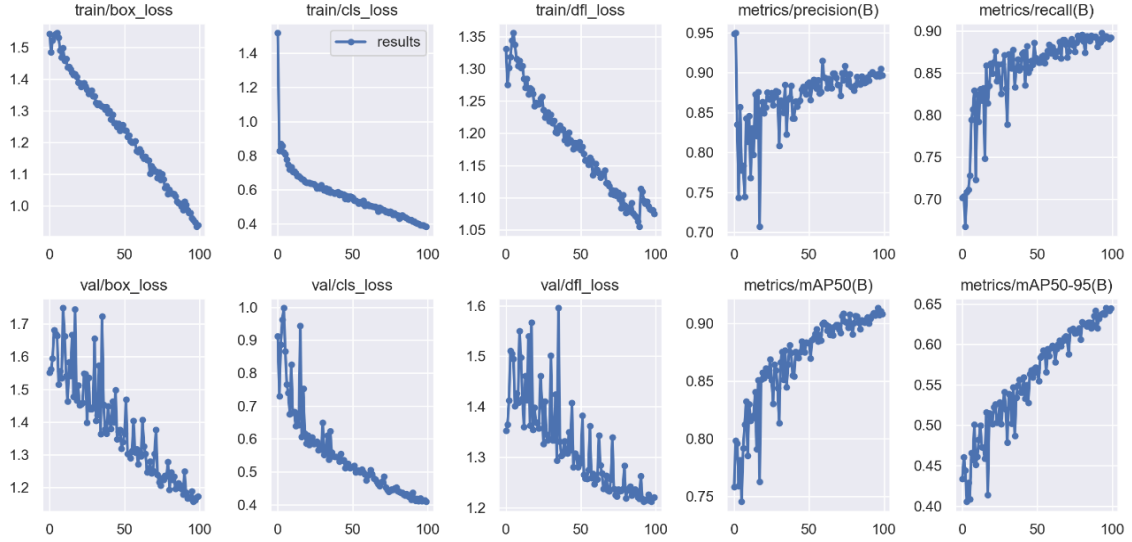


Şekil 11. F1-skor parametresinin değişim grafiği.



Şekil 12. Kesinlik-Duyarlılık grafiği.

Şekil 13’te, önerilen model için kayıp (loss) ve eğitim (train) eğrileri verilmiştir. Kayıp fonksiyonu, tahmin edilen değer ile gerçek değer arasındaki farklı göstermektedir ve değeri ne kadar düşük ise model o kadar iyi öğrenmiş demektir. Şekilde verilen grafiklerde model hızlı bir şekilde öğrenmeye başlamış ve sürekli kayıp değerini azaltmaya yönelik bir durum sergilemiştir. Kesinlik, duyarlılık ve mAP parametrelerine bağlı eğitim grafikleri ise modelin başarı değerleridir ve güven aralığıdır. Bunlar için ulaşılan değerler incelendiğinde ise şekilde görüldüğü gibi modelin ezberlemeden doğru bir öğrenme, tahminleme ve tespit yaptığı belirlenmiştir.




Şekil 13. Önerilen modelin kayıp ve eğitim grafikleri.


### 3.2. Nokta Bulutu ile İniş Pisti Analizi için Elde Edilen Bulgular

Şekil 14’te üzerinde engel bulunmayan pist görüntüleri verilmiştir. Bu görüntülerde ayrıca pistin üzerinde olduğu yolda küçük bir çukur yani derinlik bulunmaktadır. Yolda bulunan bu çukurluk nokta bulutu analizi esnasında derinlik haritası çıkarırken önerilen uygulamanın doğruluğunun gösterilmesi açısından fayda sağlamıştır. Aynı yükseklik için pist; sağ, sol, ön ve arka kısımlardan görüntü alınacak şekilde çekilmiştir.

Görüntüleme işlemi gerçekleştirildikten sonra nokta bulutu formuna dönüştürülmeden önce işlenecek görüntünün kalitesinin artırılması için Şekil 15’de görüldüğü gibi gri forma dönüştürülmüştür.




Şekil 14. Nokta bulutu ile pist uygunluk analizi amacıyla kullanılan engelsiz pist görüntüleri.




Şekil 15. Gri forma dönüştürülmüş engelsiz pist görüntüsü.

Engelsiz pist görüntüsünde nokta bulutu analizi ile elde edilen siyah-beyaz derinlik haritası Şekil 16’da verilmiştir. Bu harita incelendiğinde pist üzerinde engel bulunmadığı için pist normal bir şekilde görülmüştür. Fakat pistin üst tarafında bulunan çukur kısım bu haritada siyah bir formda görünmekte ve bu durum yapılan derinlik analizinin doğru olduğunu göstermektedir. Şekil 16’da siyah-beyaz formu verilen derinlik haritasının RGB formu Şekil 17’de verilmiştir. Şekil incelendiğinde pistin üst kısmında bulunan çukurun sahip olduğu derinlik nedeniyle koyu mavi bir renk oluştuğu, pistte ise herhangi bir yükselti ya da derinlik olmadığı için pistin üzerinde bir derinlik algılanmadığı görülmüştür.




Şekil 16. Engelsiz pist görüntüsü için siyah-beyaz derinlik haritası.




Şekil 17. Engelsiz pist görüntüsü için RGB derinlik haritası.

Bu çalışmada, derinlik haritaları için oluşturulan algoritmada referans alınan RGB derinlik haritasıdır. Bu nedenle renk çizelgesi bu harita için verilmiştir. Siyah-beyaz derinlik haritasında renkler birbirine oldukça yakındır ve bu haritada grinin en koyu tonu RGB haritasında mavi renge an açık ton ise kırmızıya karşılık gelmektedir. Şekil 18'de üzerinde engel bulunan pist görüntüleri verilmiştir. Engel pistin sağ tarafında bulunmaktadır ve engelin fotoğrafa kattığı derinlik haricinde pistin üzerinde olduğu yolda aynı çukur yani derinlik bulunmaktadır. Aynı zamanda pistin yine sabit bir yükseklikten sağ, sol, ön ve arka kısımlarından görüntü alınmıştır. Bu aşama için görüntü elde edildikten sonra nokta bulutu formuna dönüştürülmeden önce işlenecek görüntünün kalitesinin artırılması için Şekil 19'da görüldüğü gibi gri forma dönüştürülmüştür.




Şekil 18. Nokta bulutu ile pist uygunluk analizi amacıyla kullanılan engelli pist görüntüleri.




Şekil 19. Gri forma dönüştürülmüş engelli pist görüntüsü.

Gri forma dönüştürülmüş olan görüntünün siyah-beyaz derinlik haritası Şekil 20’de verilmiştir. Bu harita incelendiğinde hem pist üzerinde bulunan engelin hem de pistin üst kısmındaki yolda bulunan çukurun derinliğinin daha fazla olduğu ve o kısımların daha koyu renkli görüldüğü anlaşılmaktadır. Siyah, beyaz formda verilen derinlik haritasının RGB formatı ise Şekil 21’de gösterilmiştir. RGB formatı incelendiğinde ise derinliğin fazla olduğu noktalar mavi renkte, derinliğin az olduğu renkler ise kırmızı renkle gösterilmiştir. Yani Şekil 20’de siyah renkle görülen ve derinliği olan kısımlar mavi, beyaz renkle görülen kısımlar ise kırmızı rengi almıştır. Arada kalan derinlikler ise kırmızı, mavinin tonlarını ve sarı rengini almıştır. RGB derinlik haritası incelendiğinde de aynı şekilde pist üzerindeki engel ve yolda bulunan çukurun derinliği net bir şekilde görülmüştür.



Şekil 20. Engelli pist görüntüsü için siyah-beyaz derinlik haritası.



Şekil 21. Engelli pist görüntüsü için RGB derinlik haritası.

#### 4. Sonuçlar ve Öneriler

Genel yapısı itibarıyla kullanım alanlarına göre farklı donanım ve yazılımlara sahip olan İHA'lar içerisinde bulundukları sensör, kamera gibi aygıtlarla kullanıcıların ihtiyaçlarına cevap vermektelerdir. İHA'lar açısından iniş aşaması ve bu aşamada gerçekleşen kazalar büyük önem arz etmektedir. Bu çalışmada, iniş esnasında gerçekleşecek kazaların erken tespiti edilebilmesi ve önlenmesi amacıyla bir uygulama çalışması önerilmiştir. Bu amaç doğrultusunda öncelikle İHA'lar hakkında genel bilgiler verilerek, avantajlarından, ülkemizdeki ve dünyadaki kullanım durumlarından bahsedilmiştir. Daha sonra dört rotorlu bir İHA kullanılarak gerçek videolar ve görüntüler alınmıştır. İHA'nın kamerasından alınan görüntüler kullanılarak inişini gerçekleştirmesi için tasarlanan pist farklı açı ve yüksekliklerden kayıt altına alınmıştır. Kayıt altına alınan pist görüntüleri üzerinde RoboFlow uygulaması sayesinde pist, ağaç, uçak ve araba nesnelere etiketlenmiştir. Etiketleme için yaklaşık olarak 3528 görüntü kullanılmış, bu görüntüler eğitim, test ve doğrulama veri kümelerine bölünmüştür. Etiketleme işlemi tamamlanan görüntüler derin öğrenme tabanlı YOLOv8 modeli ile nesne tespiti yapılmıştır. Etiketleme işlemi önerilen YOLOv8 modeli ile nesne tespiti sağlanarak elde edilen görüntülerdeki araba, pist, uçak ve ağaç nesnelere

sınırlayıcı kutular ile gösterilerek model için ortaya çıkan çalışma eğrileri yorumlanmıştır. Keskinlik, duyarlılık ve F1-skor parametreleri için elde edilen grafiksel sonuçlar nesne tespitinin başarılı bir şekilde gerçekleştiğini açıkça göstermiştir.

Günümüzde birçok alanda kullanılan nokta bulutu yöntemi havacılık sektöründe iniş pisti ile ilgili verilerin elde edilmesi için de uygulanabilir düzeydedir. Bu çalışmada da PyCharm ortamında Python dili kullanılarak verilen pist görüntülerinin nokta bulutu yöntemi ile uygunluk analizi yapılmıştır. PyCharm ortamına, pistin üzerinde engel bulunmayan ve bulunan görüntüleri aktarılmış ve engelin bulunduğu görüntülerin derinlik haritaları incelendiğinde engel, görüntü içinde bir derinlik oluşturmuştur. Siyah-beyaz formda ve RGB formunda elde edilen derinlik haritaları sayesinde, uçuşunu tamamlayan İHA'nın inişi için pistin uygunluğu kontrol edilebilir hale gelmiştir.

Sonuç olarak bu çalışmada, görüntü işleme ile İHA iniş pisti tespiti sağlandıktan sonra, pistin iniş uygunluğu nokta bulutu verisi kullanılarak analiz edilmiş ve başarılı sonuçlar elde edilmiştir. Ayrıca görüntü işlemede YOLOv8 kullanılması bu işlemlerin hızını artırarak zamandan tasarruf sağlanmıştır. Bu çalışmada tasarlanan sistem ile İHA'larda iniş aşamasında gerçekleşebilecek kaza oranları düşürülebilir ve oluşabilecek diğer problemler de erken tespit edilebilir düzeye gelmiştir. Gerekli ağlar, öğrenme biçimleri ve uygulamalar kullanılarak İHA'lar için inişin kolay ve kayıpsız bir şekilde gerçekleştirilebileceği gösterilmiştir.

Teknolojik gelişmeler ve bu konuya olan ilginin bu denli fazla olmasından dolayı gelecek yıllarda yapılacak çalışmalarda, İHA sistemleri için sadece iniş anında değil uçuş esnasında ya da otonom iniş-kalkış esnasında bu yöntem kullanılarak daha fazla ilerlemeler sağlanabilir. Farklı kamera tipleri ile farklı yükseklik ve açılardan alınacak görüntüler ile farklı veri setleri oluşturulabilir ve bu veri setleri için de değerlendirmeler yapılabilir. Araştırmamız boyunca edindiğimiz bilgiler ışığında, İHA sistemleri ulaşım, haberleşme, lojistik ve daha birçok alanda derin öğrenme ağlarını kullanarak karşımıza çıkacak gibi durmaktadır. Bu durum da insan kontrolüne olan ihtiyacı azaltma eğilimini göstermektedir. Ayrıca kullanılacak olan farklı öğrenme katmanlarıyla istenilen her özellik İHA sistemleri ile rahatlıkla bütünleştirilerek öğrenmelerinin gerçekleştirilebilir olmasının diğer farklı gelişmelere öncülük edeceği düşünülmektedir.

### Kaynaklar

- [1] Mohsan SAH, Othman NQH, Li Y. et al. Unmanned aerial vehicles (UAVs): practical aspects, applications, open challenges, security issues, and future trends. *Intel Serv Robotics* 2023; 16: 109–137.
- [2] Rolly RM, Malarvezhi P, Lagkas TD. Unmanned aerial vehicles: Applications, techniques, and challenges as aerial base stations. *International Journal of Distributed Sensor Networks*. 2022;18(9): doi:10.1177/15501329221123933.
- [3] Mohsan SAH, Khan MA, Noor F, Ullah I, Alsharif M.H, Applications of Unmanned Aerial Vehicles. *Encyclopedia*. Available online: <https://encyclopedia.pub/entry/25512> (accessed on 27 October 2023).
- [4] Shakhateh H, et al., Unmanned Aerial Vehicles (UAVs): A Survey on Civil Applications and Key Research Challenges. in *IEEE Access*, 2019; 7: 48572-48634, doi: 10.1109/ACCESS.2019.2909530.
- [5] Laghari AA, Jumani AK, Laghari L. A, Nawaz H. Unmanned aerial vehicles: A review, *Cognitive Robotics*, 2023; 3: 8-22, ISSN 2667-2413, <https://doi.org/10.1016/j.cogr.2022.12.004>.
- [6] Ahmed F, Mohanta JC, Keshari A, et al. Recent Advances in Unmanned Aerial Vehicles: A Review. *Arab J Sci. Eng.* 2022; 47: 7963–7984. <https://doi.org/10.1007/s13369-022-06738-0>.
- [7] Karaköse E. Sürü İnsansız Hava Araçlarının Görev Paylaşımı için Genetik Algoritma Tabanlı Bir Yaklaşım. *Fırat Üniv. Müh. Bil. Bil. Dergisi*, 2022; 3.
- [8] Zheng X, Hu T. Air2Land: A Deep Learning Dataset for Unmanned Aerial Vehicle Auto Landing from Air to Land. *IET Cyber-Systems and Robotics* 2022; 4 (2): 77-85.
- [9] Wu L, Wang C, Zhang P, Wei C. Deep Reinforcement Learning with Corrective Feedback for Autonomous UAV Landing on a Mobile Platform. *Drones* 2022; 6(238). <https://doi.org/10.3390/drones6090238>.
- [10] Şeker A. Derin Öğrenme Yöntemleri ve Uygulamaları Hakkında Bir İnceleme, Doktora Semineri, Yıldız Teknik Üniversitesi, Fen Bilimleri Enstitüsü, 2017.
- [11] Liao T, Haridevan A, Liu Y, Shan J. Autonomous Vision-Based UAV Landing with Collision Avoidance Using Deep Learning. *Intelligent Computing*. SAI 2022; 507: Lecture Notes in Networks and Systems, Springer, Cham.
- [12] Wang J, Wei C. A Novel Air-Ground Coordinated Approach for UAV Autonomous Landing on a Mobile Platform. *Proceedings of 2022 International Conference on Autonomous Unmanned Systems ICAUS 2022: 2033–2043*.
- [13] Muraleedharan N, Cohen D. S, et al. Modelling and simulation of UAV systems. In book: *Imaging and Sensing for Unmanned Aircraft Systems*. 2020; 1(5): Control and Performance, 101-121, April 2020.
- [14] Mateja K, Skarka W, Peciak P, Niestroj R, Gude M. Energy Autonomy Simulation Model of Solar Powered UAV, *Energies* 2023; 16(1): 479, <https://doi.org/10.3390/en16010479>.
- [15] Aksu M, Karaköse E. İnsansız Hava Araçlarında Pekiştirmeli Öğrenme Kullanılarak Yükseklik Kontrolü, *Fırat Üniversitesi Uzun ve Savunma Teknolojileri Dergisi*, 12 /2022.

- [16] Yaşar S. N, Karaköse E. Trajectory Control of Quadcopter in Matlab Simulation Environment, 2022 International Conference on Decision Aid Sciences and Applications (DASA).
- [17] Karaköse E, Karaköse M, Yilmazer M. Multi-Package Delivery Optimization with Drone, 2021 International Conference on Data Analytics for Business and Industry (ICDABI).
- [18] Neuville R, Bates J.S, Jonard F. Estimating Forest Structure from UAV-Mounted LiDAR Point Cloud Using Machine Learning. *Remote Sens.* 202; 13(352). <https://doi.org/10.3390/rs13030352>.
- [19] Grlj CG, Krznan N, Pranjić M. A Decade of UAV Docking Stations: A Brief Overview of Mobile and Fixed Landing Platforms. *Drones* 2022; 6(17). <https://doi.org/10.3390/drones601001712>.
- [20] Lee JY, Chung AY, Shim H, Joe C, Park S, Kim H. UAV Flight and Landing Guidance System for Emergency Situations. *Sensors* 2019; 19: 4468. <https://doi.org/10.3390/s19204468>.
- [21] Nguyen PH, Kim KW, Lee YW, Park K.R. Remote Marker-Based Tracking for UAV Landing Using Visible-Light Camera Sensor. *Sensors* 2017; 17: 1987. <https://doi.org/10.3390/s17091987>.
- [22] Demirtaş MA. Derin Öğrenme İle 3 Boyutlu Nokta Bulutlarının Sınıflandırılmasına Genel Bir Bakış. *Dicle Üniversitesi Mühendislik Fakültesi Mühendislik Dergisi.* 13 (1): 1 - 9, 30.03.2022.
- [23] Yang T, Li P, Zhang H, Li J, Li Z, Monocular Vision SLAM-Based UAV Autonomous Landing in Emergencies and Unknown Environments. *Electronics* 2018; 7(73).
- [24] Chang CW, Lo LY, Cheung HC, Feng Y, Yang AS, Wen CY, Zhou W. Proactive Guidance for Accurate UAV Landing on a Dynamic Platform: A Visual-Inertial Approach. *Sensors* 2022; 22(404). <https://doi.org/10.3390/s22010404>.
- [25] Ge Z, Jiang J, Pugh E, Marshall B, Yan Y, Sun L. Vision-Based UAV Landing with Guaranteed Reliability in Adverse Environment. *Electronics* 2023; 12(967). <https://doi.org/10.3390/electronics12040967>.
- [26] Xin L, Tang Z, Gai W, Liu H. Vision-Based Autonomous Landing for the UAV: A Review. *Aerospace* 2022; 9(634). <https://doi.org/10.3390/aerospace9110634>
- [27] Fırıldak K, Talu F. Evrişimsel Sinir Ağlarında Kullanılan Transfer Öğrenme Yaklaşımlarının İncelenmesi, *Anatolian Journal of Computer Science*, 2019: 88-95.
- [28] Venugopalan TK, Taher T, Barbastathis G. Autonomous landing of an Unmanned Aerial Vehicle on an Autonomous Marine Vehicle, 2012 Oceans, Hampton Roads, VA, USA, 1-9, doi: 10.1109/OCEANS.2012.6404893.
- [29] Galimov M, Fedorenko R, Klimchik A. UAV Positioning Mechanisms in Landing Stations: Classification and Engineering Design Review. *Sensors* 2020; 20(3648). <https://doi.org/10.3390/s20133648>.
- [30] Xu R, Liu C, Cao Z, Wang Y, Qian H. A Manipulator-Assisted Multiple UAV Landing System for USV Subject to Disturbance. *Computer Science, Robotics.* 2 Sep 2023.
- [31] Yu L, Luo C, Yu X, Jiang X, Yang E, Lu C, Ren P. Deep Learning For Vision-Based Micro Aerial Vehicle Autonomous Landing, *International Journal of Micro Air Vehicles.* 2018;10(2): 171-185. doi:10.1177/1756829318757470.
- [32] Biçer Y, Moghadam M, et al. Vision-based UAV for Autonomous Landing with Deep Neural Networks, Session: Learning, Reasoning, and Data Driven Systems I, Published Online:6 Jan 2019.
- [33] Saygılı Z, Özmen G. İnsansız Hava Araçlarında Gömülü Sistem Üzerinden Derin Öğrenme ile Nesne Tespiti. *Avrupa Bilim ve Teknoloji Dergisi, Özel Sayı 34:* 292-298, Mart 2022.
- [34] Usta A, Arserim MA. İnsansız Hava Aracından Çekilen Videolar Kullanılarak Derin Öğrenme Yaklaşımı ile Nesne Tespiti, *DUJE (Dicle University Journal of Engineering.* 2023; 14(1): 9-15.
- [35] Şin B, Kadioğlu İ. İnsansız Hava Aracı (İHA) ve Görüntü İşleme Teknikleri Kullanılarak Yabancı Ot Tespitinin Yapılması. *Tokat Gaziosmanpaşa Üniversitesi Ziraat Fakültesi Bitki Koruma Bölümü. Turkish Journal of Weed Science* 2019; 20 (2): 211-217.
- [36] Kabadayı A, Erdoğan A, İHA Fotogrametrisi Kullanarak Yozgat Çilekçi Türbesi'nin 3 Boyutlu Nokta Bulutu ve Modelinin Üretilmesi. *Türkiye Fotogrametri Dergisi,* 2023; 5(1); 29-35.
- [37] Zheng Z, Bewley TR., Kuester F. Point Cloud-Based Target-Oriented 3D Path Planning for UAVs. 2020 International Conference on Unmanned Aircraft Systems (ICUAS), Athens, Greece, 2020. 790-798, doi: 10.1109/ICUAS48674.2020.9213894.
- [38] Han X, Jin J, Wang M, et al. A review of algorithms for filtering the 3D point cloud. *Signal Processing: Image Communication.* September 2017; 57: 103-112.
- [39] Wang H, Liu Y, Dong Z, Wang W. You Only Hypothesize Once: Point Cloud Registration with Rotation-equivariant Descriptors. *Computer Science-Computer Vision and Pattern Recognition* 2022.
- [40] Rusu RB, Cousins S. 3D is here: Point Cloud Library (PCL). 2011 IEEE International Conference on Robotics and Automation, Shanghai, China, 2011. 1-4, doi: 10.1109/ICRA.2011.5980567.
- [41] Uray F. Derin Öğrenme Tekniklerini Kullanarak Hava Lidar Nokta Bulutlarının Sınıflandırılması, *Doktora Tezi, Necmettin Erbakan Üniversitesi, Fen Bilimleri Enstitüsü Harita Mühendisliği Anabilim Dalı, Konya.* 2022.
- [42] Ahmad Fuad N, Yusoff AR, Ismail Z, Majid Z. Comparing The Performance of Point Cloud Registration Methods for Landslide Monitoring Using Mobile Laser Scanning Data, 2018 International Conference on Geomatics and Geospatial Technology, 3-5 September 2018, Kuala Lumpur, Malaysia.
- [43] Lechner A, Foody G, Boyd D. Applications in Remote Sensing to Forest Ecology and Management. *One Earth* May 2020; 2(5): 22, 405-412.



- [44] Terven J, Cordava-Esparaza D. A Comprehensive Review of YOLO: From YOLOv1 to YOLOv8 and Beyond, *Computer Science-Computer Vision and Pattern Recognition*. 2023.
- [45] Diwan T, Anirudh G, Tembhone J. Object detection using YOLO: Challenges, Architectural Successors, Datasets and Applications. *Multimed Tools Appl*. 2023; 82: 9243–9275. <https://doi.org/10.1007/s11042-022-13644-y>.
- [46] Jiang P, Ergu D, Liu F, Cai Y, Ma B. A Review of Yolo Algorithm Developments. *Procedia Computer Science* 2022; 199:1066-1073.
- [47] Kuruvilla J, Sukumaran D, Sankar A, Joy S. A Review on Image Processing and Image Segmentation. *Computer Science 2016 International Conference on Data Mining and Advanced Computing (SAPIENCE)*.
- [48] Solak S, Altınışık U. Görüntü İşleme Teknikleri ve Kümeleme Yöntemleri Kullanılarak Fındık Meyvesinin Tespit ve Sınıflandırılması, *Sakarya Üniversitesi Fen Bilimleri Enstitüsü Dergisi*, 2018; 22(1): 56-65,
- [49] Yağmur D, Atalı G. HSL Renk Uzayında Görüntü İşleme ve Morfolojik İşlemler Kullanarak Gerçek Zamanlı Nesne Tespiti ve Sınıflandırması, *European Journal of Science and Technology Special Issue* 28: 607-613, November 2021.
- [50] Çelik A, Tekin E. Hough Transform Görüntü İşleme Yöntemiyle Ekim Makineleri için Tohum Sayma Uygulaması, *European Journal of Science and Technology Special Issue*, 260-267, Nisan 2020.
- [51] Soyhan İ, Gürel S, Tekin S. Yapay Zeka Tabanlı Görüntü İşleme Tekniklerinin İnsansız Hava Araçları Üzerinde Uygulamaları. *Avrupa Bilim ve Teknoloji Dergisi Özel Sayı* 24, S. 469-473, Nisan 2021.